UNIVERSIDADE FEDERAL DO AMAZONAS FACULDADE DE TECNOLOGIA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ROBERLÂNIO DE OLIVEIRA MELO

DETECÇÃO DE VAZAMENTO DE GÁS NATURAL EM IMAGENS USANDO FILTRO NOVIDADE

MANAUS 2012

UNIVERSIDADE FEDERAL DO AMAZONAS FACULDADE DE TECNOLOGIA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ROBERLÂNIO DE OLIVEIRA MELO

DETECÇÃO DE VAZAMENTO DE GÁS NATURAL EM IMAGENS USANDO FILTRO NOVIDADE

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas.

Orientador: Prof. Dr. Cícero Ferreira Fernandes Costa Filho Co-orientadora: Profa. Dra. Marly Guimarães Fernandes Costa

> MANAUS 2012

Ficha Catalográfica (Catalogação realizada pela Biblioteca Central da UFAM)

	Melo, Roberlânio de Oliveira
M528d	Detecção de vazamento de gás natural em imagens usando filtro novidade / Roberlânio de Oliveira Melo Manaus: UFAM, 2012. 89 f.; il. color.
	Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal do Amazonas, 2012. Orientador: Prof. Dr. Cícero Ferreira Fernandes Costa Filho Co-orientadora: Prof ^a . Dra. Marli Guimarães Fernandes Costa
	1. Gás natural 2. Imagens digitais 3. Filtro de novidade 4. Sistema <i>Closed-Circuit Television</i> I. Costa Filho, Cícero Ferreira Fernandes (Orient.) II. Costa, Marli Guimarães Fernandes (Co-orient.) III. Universidade Federal do Amazonas IV. Título
	CDU 582.8.042:662.76(043.3)

ROBERLÂNIO DE OLIVEIRA MELO

DETECÇÃO DE VAZAMENTO DE GÁS NATURAL EM IMAGENS USANDO FILTRO NOVIDADE

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas.

Aprovado em ___/__/___

BANCA EXAMINADORA

Prof. Dr. Cícero Ferreira Fernandes Costa Filho, Presidente Universidade Federal do Amazonas

Prof. Dra. Marly Guimarães Fernandes Costa, Membro Universidade Federal do Amazonas

Prof. Dr. José Raimundo Gomes Pereira, Membro Universidade Federal do Amazonas

Prof. Dr. Jozias Parente de Oliveira, Membro Universidade do Estado do Amazonas

MANAUS

2012

DEDICATÓRIA

A minha família:

Aos meus pais Jóse e Leonice, pelos valores que sempre me ensinaram ao longo da vida;

Aos irmãos Irlânio, Tibério e Cleber, pela amizade e fraternidade;

> A minha querida esposa Giane, minha fonte de inspiração.

AGRADECIMENTOS

A Deus, em primeiro lugar, por iluminar meu caminho.

Ao meu orientador, Prof. Dr. Cícero Ferreira Fernandes Costa Filho, pela dedicação com que me repassou seus conhecimentos durante o período do desenvolvimento desse trabalho. Obrigado pela paciência comigo.

A minha co-orientadora, Prof. Dra. Marly Guimarães Fernandes Costa, que aceitou o desafio desse trabalho multidisciplinar.

Ao colega Tiago Teribele Msc., pelo apoio e incentivo ao estudo.

Aos colegas Francisco Aragon, Abner, Loureiro, pela amizade, companheirismo e conselhos.

Ao amigo Emmanuel Carvalho, pelo auxílio de campo na aquisição das imagens.

Em especial agradecimento, a minha esposa Giane Melo Msc., pela estruturação dessa dissertação e correções ortográficas.

RESUMO

O presente trabalho propõe um método de detecção de vazamento de gás natural em instalações petrolíferas, especificamente em poços onshore, aplicando técnicas de reconhecimento de padrões em imagens digitais. Outros métodos de detecção de vazamento de gás natural encontrados na literatura, têm como fundamento a análise de moléculas de metano, seja aplicando o princípio catalítico ou através da absorção do espectro infravermelho, estes apresentam algumas desvantagens como vida útil reduzida e condições de falsos negativos, respectivamente. O método de detecção de vazamento de gás natural proposto é baseado na aplicação do conceito de filtro de novidade em imagens digitais oriundas do sistema Closed-Circuit Television. Para tanto foram desenvolvidos seis tipos distintos de filtros de novidade, cuja diferença entre estes filtros está no tipo de componente dos espaços de cores RGB ou HSI utilizado na formação da base de treinamento dos respectivos filtros. A melhor componente que caracteriza um vazamento de gás natural foi determinado pelas medidas de desempenho obtidas nas curvas ROC destes filtros de novidade. Os resultados obtidos no filtro de novidade R são promissores, apresentando especificidade e sensibilidade máxima igual a 96,9% e 96,1%, respectivamente e AUC média de 98,527%.

Palavras-chave: gás natural; imagens digitais; filtro de novidade; sistema *closed-circuit television*.

ABSTRACT

This dissertation proposes a method of detecting natural gas leak in oil installations, specifically in onshore oil wells, applying pattern recognition techniques in digital images. Other methods of detecting natural gas leak found in the literature, has as its foundation the analysis of methane molecules, applying the catalytic principle or through the absorption of infrared spectrum. These methods have some disadvantages such as reduced service life and conditions of false negatives, respectively. The method of detecting natural gas leak proposed is based on the application of the concept of novelty filter in digital images originated from CCTV. For this, it was tested six different types of novelty filters. The difference between these filters is in the component type of color spaces (RGB or HIS) used in forming the training base of the respective filter. The best component that characterizes a natural gas leak was determined by performance measuring using ROC curves. The results obtained in the filter of novelty R are promising, with maximum sensitivity and specificity equal to 0,969 and 0,961 respectively, and average AUC of 98.527%.

Keywords: natural gas; digital images; novelty filter; closed-circuit television system.

ÍNDICE DE ILUSTRAÇÕES

Figura 1 – Esquema geral da formação de hidrocarbonetos a partir do depósito de sedimentos
sobre a matéria orgânica até a etapa de metagênese21
Figura 2 – Ilustração do conceito de filtro de novidade no espaço R^3
Figura 3 – Diagrama de blocos que ilustra o algoritmo de treinamento do filtro de novidade 29
Figura 4 – Blocos auxiliares: (a) bloco de atraso e (b) bloco TDL
Figura 5 - Diagrama de blocos para obtenção da novidade: (a) cálculo da novidade e (b)
representação simplificada para o cálculo da novidade
Figura 6 - Ilustração de classificação de padrões como pertencentes ou não a uma
determinada classe
Figura 7 – Ilustração da extração de ROI
Figura 8 – Curva ROC: (a) representação da distribuição $f(x P)$ e $f(x N)$; (b)
representação dos pontos de corte indicados na Figura 8a e desempenho de três
classificadores distintos por meio de suas curvas
Figura 9 - Diagrama em blocos do sistema de reconhecimento de padrões de vazamento de
gás natural
Figura 10 – Modelo de câmera existente na área do poço petrolífero
Figura 11 – Área do poço petrolífero e sistema de aquisição de imagens
Figura 12 – Sistema de captura de vídeos
Figura 13 - Segmentação da ROI: (a) imagem original da área do poço, (b) offsets aplicado na
imagem original e (c) ROI resultante41
Figura 14 - Diagrama de blocos do método de formação dos conjuntos de treinamento e testes
do filtro de novidade46
Figura 15 – Curva ROC: determinação do melhor x_c
Figura 16 – Amostra de imagens coletadas da área do poço: (a) diurna livre ruído, (b) noturna
livre de ruído e sem IR, (c) noturna com vazamento e IR, (d) diurna com chuva,
(e) diurna com chuva e vazamento, (f) diurna com vazamento, (g) diurna sem
vazamento e com pessoa e (h) diurna com chuva e pessoa
Figura 17 – Componentes R, G, B, H, S e I extraídas da imagem 17(a): (a) componente R, (b)
componente G, (c) componente B, (d) componente H, (e) componente S e (f)
componente I51

Figura 18 - Distribuições de especificidade e sensibilidade do Filtro de Novidade R de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B52
Figura 19 – Distribuições de especificidade e sensibilidade do Filtro de Novidade G de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B53
Figura 20 – Distribuições de especificidade e sensibilidade do Filtro de Novidade B de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B53
Figura 21 – Distribuições de especificidade e sensibilidade do Filtro de Novidade H de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B53
Figura 22 – Distribuições de especificidade e sensibilidade do Filtro de Novidade S de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B54
Figura 23 – Distribuições de especificidade e sensibilidade do Filtro de Novidade I de acordo
com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base
formada pelo grupo B54
Figura 24 - Distribuições de especificidade e sensibilidade do Filtro de Novidade R1: base
formada pelo grupo B, excluídas dos testes as imagens noturnas com vazamento 54
Figura 25 - Distribuições de especificidade e sensibilidade do Filtro de Novidade R2: base
formada pelo grupo B, excluídas dos testes as imagens noturnas com e sem
vazamento55
Figura 26 - Desempenho do Filtro de Novidade R: curvas ROC do grupo A e B da
componente R55
Figura 27 - Desempenho do Filtro de Novidade G: curvas ROC do grupo A e B da
componente G
Figura 28 - Desempenho do Filtro de Novidade H: curvas ROC do grupo A e B da
componente B56
Figura 29 - Desempenho do Filtro de Novidade G: curvas ROC do grupo A e B da
componente H57
Figura 30 - Desempenho do Filtro de Novidade S: curvas ROC do grupo A e B da
componente S

- Figura 34 Segmentação do vazamento: (a) imagem diurna, (b) imagem 35a binarizada; (c) imagem noturna; (d) imagem 35c binarizada; (e) imagem noturna com pessoas; (f) imagem 35e binarizada; (g) imagem com chuva; (h) imagem 35g binarizada......61

ÍNDICE DE TABELAS

Tabela 1 – Produção mundial de energia primária entre 1973 e 2009
Tabela 2 – Análise elementar dos constituintes do petróleo
Tabela 3 – Composição típica do gás natural associado e não associado23
Tabela 4 – Matriz de confusão
Tabela 5 – Conjunto de imagens obtidas da área do <i>wellhead</i>
Tabela 6 – Subconjunto de imagens que constituem a classe: sem vazamento40
Tabela 7 – Subconjunto de imagens que constituem a classe: com vazamento40
Tabela 8 - Subconjunto de imagens/componentes que constituem a classe de imagens sem
vazamento42
Tabela 9 - Subconjunto de imagens / componentes que constituem a classe de imagens com
vazamento43
Tabela 10 – Divisão do banco de dados da componente em dois grupos: A e B46
Tabela 11 – Resumo das métricas de desempenho dos filtros de novidade R, G, B, H, S, I, R1
e R2
Tabela 12 – Especificidade e sensibilidade dos filtros de novidade R, G, B, H, S, I, R1 e R260
Tabela 13 - Erro padrão dos filtros de novidade: SE por grupo de treinamento (A e B) e SE
global do filtro*61
Tabela 14 – Nível do vazamento e quantidade de <i>pixels</i> classificados como com vazamento 62

LISTA DE ABREVIATURAS E SIGLAS

AIS	Autonomous and Intelligent Systems
AUC	Area Under ROC Curve
BAGI	Backscatter Absorption Gas Imaging
CBA	Congresso Brasileiro de Automática
CCTV	Circuito Fechado de Televisão
CCD	Charge-Coupled Device
DOE	Department of Energy
EGIG	European Gas pipeline Incident data Group
FN	False Negative
FP	False Positive
EPE	Empresa Pesquisa Energética
GB	Gigabyte
GN	Gás Natural
HD	Hard Disk
HSI	Hue, Saturation, Intensity (espaço de cores)
IEA	International Energy Agency
IEEE	Institute of Electrical and Electronic Engineers
Mtep	Milhões de toneladas equivalentes de petróleo
NTSC	National Television System Committee
PAL	Phase Alternating Line
PCIC	Petroleum and Chemical Industry Conference
IR	Infravermelho (IR, do inglês: infrared)
RAM	Random Access Memory
RGB	Red, Green, Blue (espaço de cores)
RM	Ressonância Magnética
ROC	Receiver Operator Characteristic
SE	Standard Error
SMRE	Safety in Mines Research Establishment
TDL	Tapped-Delay Line
TN	True Negative
TP	True Positive

TPRTrue Positive Rate

SUMÁRIO

1	INTRODUÇÃO	
2	OBJETIVOS	
2.1	GERAL	19
2.2	ESPECÍFICOS	19
3	REVISÃO BIBLIOGRÁFICA	20
3.1	O PETRÓLEO E SUA HISTÓRIA	20
3.2	COMPOSIÇÃO DO PETRÓLEO	
3.3	O GÁS NATURAL (GN)	
3.4	MÉTODOS DE DETECÇÃO DE VAZAMENTO DE GÁS NATURAL	23
3.5	APLICAÇÕES DO FILTRO DE NOVIDADE	24
4	FUNDAMENTAÇÃO TEÓRICA	27
4.1	FILTRO DE NOVIDADE	27
4.1	.1 Treinamento do Filtro de Novidade	
4.1	.2 Cálculo da Novidade	
4.1	.3 O filtro de novidade como classificador	
4.1	.4 Extração de regiões de interesse através do filtro de novidade	
4.2	ESTIMATIVA DE DESEMPENHO DE UM CLASSIFICADOR	
4.2	.1 Métricas de desempenho de classificação de imagem – Curva ROC	
5	MATERIAIS E MÉTODOS	
5.1	AQUISIÇÃO DAS IMAGENS	37
5.2	PRÉ-PROCESSAMENTO	41
5.3	EXTRAÇÃO DE CARACTERÍSTICAS	
5.4	CLASSIFICADOR BASEADO EM FILTRO DE NOVIDADE	
5.5	METODOLOGIAS PARA TREINAMENTO E TESTE	
5.5	.1 Método Metade-Metade ou <i>Holdout</i>	45
5.6	DESEMPENHO DO CLASSIFICADOR	47
5.7	ESTUDO SOBRE EXISTÊNCIA DE CORRELAÇÃO LINEAR ENTRE O NÍ	VEL DE
VA	ZAMENTO REAL E O DETECTADO NA IMAGEM	

6	RESULTADOS E DISCUSSÕES
6.1	RESULTADOS
6.1.	1 Base de dados utilizada
6.1.	2 Resultados dos filtros de novidade R, G, B, H, S, I, R1 e R251
6.1.	2.1 Da distribuição de especificidade e sensibilidade dos filtros de novidades52
6.1.	2.2 Do desempenho dos filtros de novidade R, G, B, H, S, I, R1 e R255
6.1.	2.3 Do resumo do desempenho dos filtros de novidade R, G, B, H, S, I, R1 e R259
6.1.	2.4 Do erro padrão das curvas ROC dos filtros de novidade R, G, B, H, S, I, R1 e R260
6.1.	3 Segmentação do vazamento de GN nas imagens classificadas como pertencentes à
	classe com vazamento
6.1.	4 Correlação entre vazamento e quantidade de pixels classificados como pertencentes a
	classe com vazamento
6.2	ANÁLISE E DISCUSSÃO DOS RESULTADOS63
6.2.	1 Das distribuições de especificidade e sensibilidade
6.2.	2 Do desempenho dos filtros de novidade
6.2.	3 Do desempenho do filtro de novidade R, excluídas as imagens noturnas dos testes65
6.2.	4 Da segmentação do vazamento nas imagens
6.2.	5 Da existência de correlação entre vazamento e quantidade de <i>pixels</i> classificados como
	pertencentes à classe com vazamento66
7	CONCLUSÕES67
RE	FERÊNCIAS BIBLIOGRÁFICAS69
AP	ÊNDICE A – TRABALHOS PUBLICADOS75

1 INTRODUÇÃO

Nos dias atuais, o Gás Natural (GN) vem tomando lugar de destaque como fonte de combustível no mundo. Um dos principais motivos que favorece essa situação está relacionado a questões ambientais, pois o gás natural é um combustível de queima limpa, que produz menos dióxido de carbono quando comparado ao petróleo ou ao carvão (SLOAN, 2003). O segundo motivo advém do gás natural ter maior volume e dispersão das reservas no globo terrestre em relação ao petróleo (CORTELETTI, 2009). Estes fatores fazem com que o GN tenha grande participação na matriz energética mundial.

De acordo com a *International Energy Agency* (IEA, 2011), entre os anos de 1973 e 2009, a produção mundial de gás natural aumentou 159,71%, ocupando neste último ano a terceira posição entre as maiores fontes de energia primárias produzidas no mundo, com 2.539,39 Mtep (milhões de toneladas equivalentes de petróleo), conforme Tabela 1.

Fonte de	1973	2009	Variação
Energia	(Mtep)	(Mtep)	(%)
Biomassa	647,77	1.239,32	91,32
Petróleo	2.811,10	3.985,26	41,77
Gás Natural	977,77	2.539,39	159,71
Hidráulica	110,00	279,45	154,05
Carvão	1.503,33	3.304,85	119,84
Nuclear	55,00	704,71	1.181,30
Outras	6,11	97,20	1.490,58

Tabela 1 - Produção mundial de energia primária entre 1973 e 2009

Fonte: IEA, 2011

Estudos da Empresa de Pesquisa Energética do Brasil (EPE, 2011), entre os anos 2001 e 2010, revelam que houve um incremento de 63,9% na produção brasileira deste combustível, tornando o gás natural responsável por 10,3% da matriz energética do Brasil, refletindo os atuais 9.295 km de gasodutos instalados no território brasileiro.

Apesar da evolução na produção e no consumo dos derivados petrolíferos, a indústria mundial de petróleo e gás natural é um dos campos mais complexos e perigosos devido a características intrínsecas dos hidrocarbonetos, tais como: asfixia, inflamabilidade, energia mínima de ignição e velocidade de explosão (COSTA e MELO, 2012 *apud* SOUZA, 2002). O gás natural é composto basicamente por metano, e este, por sua vez é extremamente

explosivo, apresentando limite inferior e superior de inflamabilidade de 5% e 15%, respectivamente, e energia mínima para ignição de 250µJ (ZABETAKIS, 1965).

Neste contexto, um dos acidentes de maior magnitude envolvendo este produto ocorreu em 1988 na plataforma Piper Alfa (VINNEM, 2011), que operava no Mar do Norte próximo a Aberdeen na Escócia. Após um vazamento de condensado de gás natural para atmosfera e sua combustão, 167 vidas humanas foram perdidas e a plataforma adernou (CULLEN, 1990).

Historicamente, o banco de dados *European Gas pipeline Incident data Group* (EGIG, 2011) registra que entre os anos 1970 e 2010, ocorreu uma taxa de 0,35 incidentes por ano por 1.000 km de dutos em uma malha de gasodutos de 135.000 km instalada, que se estende entre quinze países europeus. Estes incidentes ocorreram devido à interferência externa, montagens erradas, falha de material, movimentação do solo, falha de operação e outros fatores desconhecidos, tendo como consequências: explosões, incêndios, deflagrações, asfixia e intoxicação por gases de escape.

Dados coletados (SOVACOOL, 2008), em escala mundial, sobre os principais acidentes no setor energético entre os anos 1907 e 2007, estima em quase 2 bilhões de dólares os custos materiais gerados por acidentes tendo como fonte o gás natural, além de 737 vitimas fatais.

Sendo assim, a detecção de vazamento de gás natural é de grande importância para indústria petrolífera, tanto no que se refere à economia quanto à segurança de seus trabalhadores. Logo, diversos trabalhos já foram desenvolvidos tendo como foco a detecção de vazamento de gás natural, como por exemplo, o uso do princípio da combustão catalítica (FIRTH *et al.*, 1973) e absorção do espectro infravermelho (KRIER e SHERSTNEV, 2000), dentre outros.

Considerando o fato de que, normalmente, vazamentos de gás natural bruto tornamse visíveis ao ser humano em forma de uma nuvem branca ou neblina sobre duas circunstâncias: o gás ao entrar em contanto com a atmosfera induz a condensação do ar; em forma de aerossol gerado pelo gás condensado (ROSS e SOLAN, 2007). Este trabalho propõe um método de detecção de vazamento de gás em poços petrolíferos de uma instalação *onshore* utilizando um sistema de *Closed-Circuit Television* (CCTV) com *Charge-Coupled Device* (CCD) o qual monitora a área do poço.

A ideia explorada neste estudo é a utilização de técnica conhecida como filtro de novidade (KOHONEN e OJA, 1976) para investigar a presença de um vazamento de gás natural em imagens digitais capturadas por câmeras CCD, especificamente imagens da cabeça de produção de um poço petrolífero, também conhecida como "árvore de natal" ou *wellhead, christmas tree*, a qual está mais propensa a originar vazamento em virtude das inúmeras conexões e válvulas que compõem a *wellhead*.

2 OBJETIVOS

2.1 GERAL

Desenvolver método para detecção de vazamento de gás natural em poços petrolíferos *onshore* utilizando o conceito de filtro de novidade aplicado a imagens digitais obtidas por sistema de vigilância.

2.2 ESPECÍFICOS

- 2.2.1 Construir base de dados contendo informações das componentes dos espaços de cores HSI (*Hue, Saturation e Intensity*) e RGB (*Red, Green, Blue*), pertinentes às imagens originárias do sistema de CCTV da cabeça de poço (*wellhead*), que englobem cenas da região de interesse com vazamento e sem vazamento, além de imagens destas duas classes contendo ruídos.
- 2.2.2 Propor algoritmo baseado em aprendizagem supervisionada, como método de classificação de *pixels* provenientes de imagens do poço, visando à detecção de vazamento de gás natural em poço.
- 2.2.3 Tornar o sistema de detecção de vazamento robusto, propiciando ao mesmo diferenciar um vazamento de um ruído, tais como, precipitação pluviométrica, variação do gradiente de iluminação natural e presença de pessoas na área do poço.
- 2.2.4 Identificar a melhor componente dos espaços de cores (HSI e RGB) que caracterize um vazamento de gás natural.
- 2.2.5 Localizar a região na imagem correspondente ao vazamento.
- 2.2.6 Estudar a possível existência de correlação linear entre a região identificada na imagem como contendo vazamento de gás natural com volume real do vazamento gás natural.

3 REVISÃO BIBLIOGRÁFICA

3.1 O PETRÓLEO E SUA HISTÓRIA

A presença do petróleo e seus derivados no cotidiano do homem remontam a época da antiga Mesopotâmia. O betume, encontrado em exsudações naturais, era utilizado como material de liga para o assentamento de tijolos, posteriormente sua aplicação foi ampliada pelos egípcios em estradas, calafetagens, e embalsamentos (KOVACS, 1990, FORBES, 1936 e COBB *et al.*, 1995).

No século 19, na cidade de Tittusville, localizada no Estado americano de Pensilvânia, o Coronel Drake deu início ao processo de exploração comercial do petróleo ao perfurar o primeiro poço petrolífero, cuja produção era de $2m^3/dia$ de óleo. Nesta época o petróleo passou a ser destilado, tendo como um dos derivados o querosene, vindo a substituir o óleo mineral provido de baleias e carvão, que era utilizado em lâmpadas a óleo. Hoje, com o advento da tecnologia, o petróleo passou a ser imprescindível a sociedade moderna, sendo a principal fonte de energia do planeta, além das inúmeras aplicações que seus derivados proporcionam a indústria e ao comércio (THOMAS, 2004).

3.2 COMPOSIÇÃO DO PETRÓLEO

A palavra petróleo tem origem no latim *petroleum*, oriunda dos termos *petra* e *oleum*, que corresponde à expressão, literalmente, "pedra de óleo", sendo então, adotada para designar o combustível fóssil composto basicamente por moléculas de hidrocarbonetos (átomos de carbono e hidrogênio) em estado sólido, líquido ou gasoso (THOMAS, 2004 e CORREA, 2003).

Há duas teorias sobre a origem do petróleo: a teoria abiogênica e a teoria biogênica, que proporcionam um amplo debate desde a época do início da exploração comercial deste combustível. A teoria inorgânica propõe que grandes quantidades de carbonos existem naturalmente no subsolo do planeta, sendo que alguns estão na forma de hidrocarbonetos, entretanto determinados pontos desta teoria não são completamente compreendidos, como formação, alteração, ou contaminação dos depósitos de hidrocarbonetos. A teoria orgânica, amplamente difundida e aceita (GOLD, 1985), pressupõe que os hidrocarbonetos também surgem de forma natural, mas originários da sinterização de diversos tipos de matéria orgânica (vegetais, algas, plâncton, animais, etc.) armazenada em sedimentos a milhões de anos atrás, sendo submetida a uma série de processos termoquímicos conhecidos como estágios de diagênese, catagênese e metagênese, conforme Figura 1 (ROBBINS *et al.*, 2000 e WHITICAR, 1994).



Figura 1 – Esquema geral da formação de hidrocarbonetos a partir do depósito de sedimentos sobre a matéria orgânica até a etapa de metagênese Fonte: Adaptado de Tissot (1984, p. 215) e Thomas (2004, p. 16)

Após a deposição da matéria orgânica em condições adequadas, inicia-se o processo de formação do petróleo com o incremento de temperatura e carga sedimentar sobre esta matéria orgânica. Entre as temperaturas inferiores a 65°C ocorre à transformação do composto orgânico em querogênio, o que se refere à etapa de diagênese. De 65°C a 165°C, conhecida como etapa catagênese, o querogênio é convertido em hidrocarbonetos líquidos (designado, comumente de petróleo), gasoso úmido e condensado (ambos conhecidos como gás natural). Até 210°C ocorre o craqueamento das moléculas mais pesadas, resultando em moléculas leves, ou seja, gás seco rico em hidrocarbonetos, este processo é denominado metagêneses. Acima de 210°C a mistura resultante passa a ser pobre em hidrocarbonetos e rica em gás carbônico (CO_2) e grafite (THOMAS, 2004).

A composição do petróleo pode diferenciar de um campo petrolífero para outro, apresentando características distintas como viscosidade, cromaticidade, densidade ou gravidade específica (THOMAS, 2004). No entanto, conforme McCain (1990), quase todos os fluídos do petróleo possuem análise elementar dentro dos limites indicados na Tabela 2, sendo possível identificar que mais de 90% da composição desta fonte de energia é constituída, basicamente, de carbono e hidrogênio.

Elemento	Composição (% em peso)
Carbono	84 - 87
Hidrogênio	11 – 14
Enxofre	0,06 - 2,0
Nitrogênio	0,1-2,0
Oxigênio	0,6-2,0

Tabela 2 - Análise elementar dos constituintes do petróleo

Fonte: Adaptado de McCain (1990, p. 3)

3.3 O GÁS NATURAL (GN)

Os persas, por volta de 2000 a.C., já conheciam o gás natural como o "fogo eterno" que brotava da terra e nunca se extinguia, embora nesta época o seu poder energético não era reconhecido. Durante a dinastia Han (200 a.C.), os chineses transportavam o gás natural por meio de gasodutos construídos de bambu, para ser inflamado, visando à iluminação e evaporação de salmouras e consequentemente produção de sal (WU e CARROLL, 2008 e NEEDHAM *et al.*, 1965).

A Lei Federal número 11.909/09, que versa sobre as atividades de tratamento, processamento, estocagem, liquefação, regaseificação, comercialização e transporte de gás natural, conceitua o GN como: "todo hidrocarboneto que permaneça em estado gasoso nas condições atmosféricas normais, extraído diretamente a partir de reservatórios petrolíferos ou gaseíferos, cuja composição poderá conter gases úmidos, secos e residuais".

Em termos científicos, o gás natural pode ser considerado a parcela do petróleo que se encontra no estado gasoso (não associado) ou em solução no petróleo (associado), formado por moléculas de hidrocarbonetos alifáticos saturados, ou seja, apresentam cadeia aberta com simples ligações, cuja fórmula geral é dada por $C_n H_{2n+2}$ (WHITICAR, 1994). Os principais

alcanos que compõem o GN são o metano (CH₄), etano (C₂H₆), propano (C₃H₈), butano (C₄H₁₀) e o pentano (C₅H₁₂) e, em menores proporções, de outros hidrocarbonetos de maior peso molecular, além de traços de compostos não hidrocarbonetos, sendo que 70 a 98% do GN é composto por metano, conforme Tabela 3 (MCCAIN, 1990).

Tipo de	Componente	Fórmula	Gás não associado	Gás associado
Componente	Componente	molecular	(% em peso)	(% em peso)
	Metano	CH_4	70 - 98	45 - 92
	Etano	C_2H_6	1 - 10	4 - 21
TT 1 1	Propano	C_3H_8	traços – 5	1 - 15
Hidrocarbonetos	Butano	C_4H_{10}	traços – 1	0,5 - 7
	Pentano	C_5H_{12}	traços – 0,5	traços – 3
	Hexano	C_6H_{14}	traços – 1	traços – 2
	Heptano	$C_{7}H_{16}$	$0,\!0-0,\!5$	0,0 - 1,5
Não	Nitrogênio	N ₂	traços – 15	traços – 10
Hidrocarboneto	Dióxido de Carbono	CO_2	traços – 5	traços – 4
	Sulfeto de hidrogênio	H_2S	traços – 3	$0,\!0-6$
	Hélio	He	traços – 5	0,0

Tabela 3 - Composição típica do gás natural associado e não associado

Fonte: Adaptado de McCain (1990, p. 2)

Dado o volume do metano presente no gás natural, diversos métodos para detecção de gás natural baseiam-se em detectar o vazamento de metano para a atmosfera. Na sequência são expostos alguns desses métodos de detecção de vazamento de gás natural, já desenvolvidos.

3.4 MÉTODOS DE DETECÇÃO DE VAZAMENTO DE GÁS NATURAL

O Safety in Mines Research Establishment (SMRE) propôs o princípio da combustão catalítica para medir a concentração do CH_4 presente no ambiente (FIRTH *et al.*, 1973). Este princípio baseia-se no aumento da temperatura resultante do calor gerado pela combustão do metano na superfície catalítica, empregando o paládio como elemento sensor. Devido à facilidade de fabricação e baixo custo, este tipo de dispositivo pontual vem sendo utilizado até os dias atuais. Estes sensores, no entanto, têm vida útil relativamente reduzida e a detecção de CH_4 é limitada a uma faixa estreita de concentração do CH_4 no ambiente (FAN *et al.*, 2007).

A análise sobre a absorção do espectro infravermelho (IR) também vem sendo utilizada com frequência na detecção do metano. Os principais motivos que levam à utilização deste método pontual são os seguintes: vida útil do detector por IR (superior a cinco anos), estabilidade e a confiabilidade. O sistema de detecção por IR é composto por transmissores e receptores de IR com espectro eletromagnético com a faixa de comprimento de onda situada em $\lambda_{IR} = 2 \sim 5 \mu m$. Quando a radiação IR interage com o gás metano $(\lambda_{CH_4} \approx 3.5 \mu m)$, parte da energia é absorvida e o restante é transmitida (KRIER e SHERSTNEV, 2000). A concentração de gás é obtida através da medida da razão entre a radiação incidente e a transmitida (FAN, 2007). Porém estes sistemas apresentam desvantagens, como a dificuldade de instalação e de manutenção e os alarmes de falsos (detecção de falsos positivos) na presença de vapor de água, pois a radiação IR também é absorvida por esta substância.

Outra técnica utilizada cada vez mais na detecção de vazamentos de gás natural é a de processamento digital de imagem. Em 1993, o *U.S. Department of Energy* (DOE), em conjunto com o *Sandia of National Laboratories do National Security Missions* (MCRAE, 1993), propôs um sistema chamado de *Backscatter Absorption Gas Imaging* (BAGI), cujo princípio básico era iluminar um cenário contendo vazamento de GN, aplicando uma iluminação laser IR, e em seguida fotografar este vazamento usando uma câmara IR.

Sistemas que empregam a tecnologia IR são caros (KASTEK, 2008a e KASTEK, 2008b), atingindo valores de U\$ 80.000,00 e são utilizadas em inspeção e não para monitoramento contínuo.

Enfim, outros métodos para detecção de vazamentos já foram desenvolvidos, como por exemplo, ultrassônicos e eletroquímicos (HUSEYNOV *et al.*, 2009), os quais não serão apresentados neste trabalho por não se tratar de um estudo sobre as técnicas já desenvolvidas.

3.5 APLICAÇÕES DO FILTRO DE NOVIDADE

Na literatura, inúmeros estudos em diversas áreas já foram desenvolvidos tendo como base a aplicação de filtro de novidade descrito em Kohonen e Oja (1976). O leque de aplicação do filtro de novidade se expande da segmentação fonética (HALTSONEN *et al.*, 1978), detecção de lesões de esclerose múltipla em imagens de ressonância magnética (RAFF e NEWMAN, 1990), identificação de lesões em imagens cintilográficas de mamas (COSTA e MOURA, 1995), predição de falhas em equipamentos (ELSIMARY, 1996), até o

reconhecimento de indivíduos através da íris (COSTA *et al.*, 2011). No entanto, é escasso o conteúdo literário no que tange o processamento de sequência de imagens (vídeo) utilizando o filtro de novidade, que é à base da deste trabalho.

Haltsonen *et al.* (1978), propuseram um sistema voltado para a segmentação e reconhecimento de fonemas contidos em um discurso, detectando a novidade presente na decomposição espectral da forma de onda da fala, em relação a um conjunto de fonemas previamente armazenados.

Raff e Newman (1990) desenvolveram um método para detecção automática de lesões de esclerose múltipla analisando imagens de ressonância magnética (RM). O esquema é baseado no treinamento de uma rede neural com imagens RM de pacientes normais e posteriormente é apresentada a esta rede uma imagem RM com lesões, sendo então extraída a "novidade" de imagem apresentada.

Costa e Moura (1995) propuseram uma nova técnica de detecção e classificação de lesões (malignas ou benignas) contidas em imagens de cintilografia mamária. A característica principal do método proposto foi apontar para a necessidade da padronização das imagens de cintilografias, antes destas serem utilizadas para compor a base de treinamento do filtro de novidade ou que elas sejam apresentadas ao sistema para análise. Quando uma imagem de teste é submetida à entrada do sistema, a saída do mesmo apresenta uma imagem da mama com as lesões identificadas.

Elsimary (1996) investigou a detecção de falhas mecânicas e espiras em curto em máquinas rotativas em funcionamento. Partindo do pressuposto de que qualquer alteração nas condições do motor (desgaste nos mancais, falhas de isolamento e curto circuito de espiras) será refletida no perfil atual da corrente elétrica que supre a máquina. O autor propôs um algoritmo genérico, baseado em filtro de novidade, onde todas as réplicas de padrões conhecidos do espectro da corrente elétrica de motores são armazenadas em memória auto-associativa. Em seguida, a corrente elétrica atual do motor é comparada com os padrões pré-armazenados. Se houver divergência (novidade) é então configurada a existência de uma falha na máquina.

Recentemente, a linha de pesquisa voltada para o reconhecimento biométrico do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas foi reforçada com a publicação de um novo método, robusto, de reconhecimento de indivíduos através da análise da íris (COSTA *et al.*, 2011), tendo como fundamentação o filtro de novidade. Os autores definem o processo de classificação usando um filtro de novidade,

onde uma imagem de prova de uma íris é comparada a um dos modelos previamente armazenados. A norma do vetor novidade é utilizada como medida de dissimilaridade.

4 FUNDAMENTAÇÃO TEÓRICA

Os principais conceitos teóricos que alicerçam esta proposta de dissertação são apresentados nesta seção.

4.1 FILTRO DE NOVIDADE

O conceito de filtro de novidade foi descrito em Kohonen e Oja (1976), como um tipo de memória auto-associativa. Nesta sequência, o conceito filtro de novidade é descrito com base no método clássico de ortogonalização de Gram-Schmidt (COSTA *et al.*, 1995), o qual pode ser utilizado na arquitetura de reconhecimento de padrões como um classificador.

Seja $\{x_1, x_2, ..., x_m\} \in \mathbb{R}^n$ um conjunto de vetores euclidianos de dimensão n que geram um subespaço $L \subset \mathbb{R}^n$ de dimensão m com m < n. Considerando o subespaço L, um vetor arbitrário, $x \in \mathbb{R}^n$, pode ser decomposto em duas componentes $\hat{x} \in \tilde{x}$, onde $\hat{x} \in L$ e $\tilde{x} \perp L$ que é a projeção perpendicular de x em relação à L. O vetor $\hat{x} \in L$ representa a componente de x que é "conhecida" pelo subespaço L e pode ser representada pela combinação linear de $\{x_1, x_2, ..., x_m\}$. O vetor $\tilde{x} \perp L$ representa a informação "nova", que é "desconhecida" pelo subespaço L e não pode ser representado como uma combinação linear de $\{x_1, x_2, ..., x_m\}$. A Figura 2 ilustra essas duas componentes no espaço \mathbb{R}^3 (COSTA E MOURA, 1995).



Figura 2 – Ilustração do conceito de filtro de novidade no espaço R^3 Fonte: Adaptado de Costa e Moura, 1995

Assim, considerando o subespaço L, \tilde{x} é chamado de novidade e o sistema que extrai esta componente de x pode ser chamado de Filtro de Novidade.

Para se determinar as componentes $\hat{x} \in \tilde{x}$ de um vetor x, é utilizado o processo de ortogonalização de Gram-Schmidt (KOHONEN, 1989). Considerando um conjunto de m vetores independentes $\{x_1, x_2, ..., x_m\}$, a base L, pode-se obter m vetores ortogonalis $\{v_1, v_2, ..., v_m\}$ através do procedimento descrito pelas equações (1) e (2):

$$v_1 = x_1 \tag{1}$$

$$v_k = x_k - \sum_{i=1}^{k-1} \frac{(x_k, v_i)}{(v_i, v_i)} v_i, \quad k = 2, 3, ..., m$$
(2)

onde $\sum_{i=1}^{k-1} \frac{(v_i, x_k)}{(v_i, v_i)} v_i$ é a projeção de x_k em v_i .

Dado um vetor de amostra x, sua componente "novidade" é calculada como o passo (m+1) do processo descrito na equação (2), ou seja, $\tilde{x} = v_{k+1}$, tal como descrito na equação (3).

$$\widetilde{x} = x - \sum_{i=1}^{m} \frac{(v_i, x)}{(v_i, v_i)} v_i$$
(3)

Portanto, a magnitude do vetor \tilde{x} , $\|\tilde{x}\|$, pode usada como medida de dissimilaridade, pois quanto menor a magnitude de \tilde{x} , mais próximo este será a base $\{v_1, v_2, ..., v_m\} \in \mathbb{R}^n$, consequentemente o vetor arbitrário x possui elevada combinação linear os m vetores que foram à base vetorial.

4.1.1 Treinamento do Filtro de Novidade

O filtro de novidade pode ser compreendido como um classificador que emprega um treinamento supervisionado. Diferentemente de redes neurais, o conjunto de treinamento do filtro de novidade consiste apenas de vetores que pertencem a uma determinada classe. O treinamento consiste em gerar o conjunto $\{v_1, v_2, ..., v_m\}$ a partir do conjunto de treinamento $\{x_1, x_2, ..., x_m\}$ de acordo com as equações (1) e (2).

O diagrama de blocos da Figura 3 ilustra o algoritmo de treinamento. Para compreensão desse diagrama dois outros conceitos são necessários: bloco de atraso e o bloco de linha de atrasos com derivações ou *tapped-delay line* (TDL).

Um bloco de atraso é representado pela Figura 4a. Quando k = 0 a saída v_k do bloco de atraso será igual à entrada vertical x_0 . Para $k \neq 0$ a saída v_k será igual à entrada no momento $v_k - 1$. O bloco TDL é representado na Figura 4b, consistindo de uma entrada e várias saídas, constituído da entrada atual em k tempo e de outras saídas atrasadas de 1 a k.



Figura 3 - Diagrama de blocos que ilustra o algoritmo de treinamento do filtro de novidade



Figura 4 – Blocos auxiliares: (a) bloco de atraso e (b) bloco TDL

Portanto, o algoritmo de treinamento do filtro de novidade pode ser ilustrado por meio de diagramas de blocos na Figura 4, no qual os vetores de treinamento de entrada são $\{x_1, x_2, ..., x_m, 0\}$. Os componentes deste conjunto são aplicados sequencialmente à entrada do bloco de treinamento.

No momento k = 0, a entrada é x_1 e a saída v_k será igual $v_0 = x_0$. No instante k = 1, a entrada é x_2 e a saída será igual à entrada do bloco de atraso $k = 0, v_1$. No instante k = m o treinamento e TDL cessam, tendo como saída o conjunto $\{v_1, v_2, ..., v_m\}$.

4.1.2 Cálculo da Novidade

Para calcular o vetor novidade \tilde{x} , basta aplicar a entrada x ao conjunto congelado, como mostrado no diagrama em blocos da Figura 5a. A entrada x corresponde a uma amostra a partir da qual se quer calcular a novidade. O diagrama de blocos da Figura 5a pode ter uma representação simplificada, como mostrado na Figura 5b.



Figura 5 – Diagrama de blocos para obtenção da novidade: (a) cálculo da novidade e (b) representação simplificada para o cálculo da novidade

4.1.3 O filtro de novidade como classificador

Em termos de reconhecimentos de padrões, a norma da novidade $\|\tilde{x}\|$ do filtro de novidade pode ser aplicada para solucionar problemas no qual se deseja classificar um padrão como pertencente ou não a uma classe, como por exemplo, a imagem possui ou não vazamento. Nesta aplicação, a primeira tarefa é o treinamento do filtro de novidade com amostras de uma mesma classe, por exemplo, imagens sem vazamento. A segunda é escolher um conjunto de teste formado por padrões que pertençam a esta classe e padrões que não pertençam a esta classe. Cada membro do presente conjunto é aplicado ao filtro de novidade treinado e, em seguida, a norma da novidade é calculada.

A princípio espera-se que as normas dos padrões que pertencem à mesma classe do treinamento sejam menores do que as normas dos padrões que não pertencem à classe. Portanto, um limiar ótimo será determinado para separar esses dois subconjuntos.

Nesta dissertação, o limiar ótimo foi determinado utilizando o conceito de curva ROC (*Receiver Operating Characteristic*) que maximiza a sensibilidade e especificidade do filtro a ser apresentando ao longo desta proposta.

Logo, após o treino, uma amostra x pode ser classificada como pertencendo ou não a classe utilizada para treinamento do filtro de novidade, como ilustrado no diagrama de blocos da Figura 6. Se a saída do diagrama em blocos da Figura 6 for igual a 0, a imagem pertence à classe de imagens utilizada para treinamento do filtro de novidade (imagens sem vazamento). Caso contrário, se a saída for igual a 1, a imagem não pertence à classe de imagens utilizada para treinamento do filtro de novidade e, portanto, é uma imagem com vazamento.



Figura 6 – Ilustração de classificação de padrões como pertencentes ou não a uma determinada classe.

4.1.4 Extração de regiões de interesse através do filtro de novidade

O filtro de novidade apresentando até o momento permite classificar uma entrada x, como pertencente ou não a classe de treinamento do filtro de novidade, conforme representado na Figura 6. Entretanto, outra aplicação do filtro de novidade a ser utilizada neste trabalho visa detectar regiões do vetor novidade, denominadas de Regiões de Interesse (ROI, do inglês: *Regions of Interest*) que correspondem à novidade propriamente dita, ou seja, dada uma imagem do poço que contenha um vazamento, o filtro de novidade permite identificar na imagem as regiões do poço onde o vazamento ocorreu. Logo, as regiões identificadas na imagem como "vazamento" são *pixels* não pertencentes à classe de treinamento do filtro de novidade.

O desenvolvimento desta segunda aplicação para o filtro de novidade inicia-se treinando o filtro de novidade com um conjunto de treinamento composto por vetores que não

possuem ROI, ou seja, pertencem a classe sem vazamento. A segunda etapa é escolher um conjunto de teste composto por dois subconjuntos: um conjunto composto de vetores sem ROI e outro composto de vetores com ROI, conforme procedimentos descritos nas seções 4.1.1 a 4.1.4.

Logo, dada uma amostra x qualquer e esta classificada como pertencente à classe com vazamento, é possível aplicar um limiar a cada coordenada no vetor \tilde{x} , de tal forma que se o valor de uma coordenada do vetor novidade for inferior a este limiar, a coordenada correspondente no vetor de saída é 0. Se for superior ao limiar, a coordenada correspondente no vetor de saída é de 1. Através desse procedimento, então, a ROI no vetor de saída (ou imagem de saída) é o conjunto de todas as coordenadas do vetor de saída (da imagem) com um valor igual a 1. Neste trabalho, o limiar adotado é a média dos valores do vetor \tilde{x} . Na Figura 7, é ilustrado o diagrama de blocos para extração da ROI.



Figura 7 – Ilustração da extração de ROI.

4.2 ESTIMATIVA DE DESEMPENHO DE UM CLASSIFICADOR

Uma vez definido o classificador, cabe avaliar o seu desempenho. A avaliação do desempenho de um classificador é importante quando se quer fazer uma comparação entre algoritmos diferentes e também prever, de forma confiável, como um algoritmo irá se comportar quando aplicado na prática.

De acordo com Bowyer (2000), o conceito de desempenho pode assumir duas definições distintas. A primeira está relacionada ao tempo necessário para executar um algoritmo computacional. Nesse contexto, o algoritmo que executar a classificação em um menor tempo é considerado o melhor. A segunda definição de desempenho diz respeito à frequência com a qual um algoritmo produz decisões corretas. Nesse contexto, o melhor algoritmo é aquele que produz decisões corretas com mais frequência que outro algoritmo.

Este trabalho apoia-se na segunda definição de desempenho, pois avalia qual dos algoritmos constituídos pelas componentes R, G, B, H, S e I (dos espaços de cores RGB e HSI) que melhor classifica um vazamento de gás natural.

4.2.1 Métricas de desempenho de classificação de imagem – Curva ROC

Em um ambiente de classificação do conteúdo de uma imagem (normal ou anormal, presença ou ausência, com ou sem vazamento), o classificador pode produzir quatro resultados distintos: verdadeiro positivo (TP do inglês: *True Positive*), falso positivo (FP do inglês: *False Positive*), verdadeiro negativo (TN do inglês: *True Negative*), e falso negativo (FN do inglês: *False Negative*). Os termos positivo e negativo referem-se à decisão tomada pelo algoritmo de detecção, sendo que os termos verdadeiro e falso remetem a decisão do algoritmo estar de acordo com a situação real.

Logo, um resultado TP significa que o classificador detectou corretamente uma anormalidade existente na imagem. Já o FP expressa que o classificador classificou como anormal uma imagem que na realidade é normal. O TN indica que o algoritmo decidiu corretamente que nenhuma anormalidade existe na imagem. E por fim, o FN indica que o algoritmo detectou erradamente que nenhuma anormalidade existe na imagem. Estas definições podem ser expressas por meio da tabela de confusão 4. Essa tabela constitui a base para obtenção da curva ROC (PRATI *et al.*, 2000).

Classe Verdadeira	Classe Predita (decisão do algoritmo)		
(Shuuyuo Tour)	р	n	
p (positivo)	ТР	FN	
n (negativo)	FP	TN	

Tabela 4 - Matriz de confusão

Fonte: Adaptado de Prati (2000)

Dado os conceitos de TP, FP, TN e FN é possível, então, compreender a formação da curva ROC. A curva ROC foi concebida originalmente entre 1950 e 1960 para determinar a qualidade de transmissão de sinal em um canal contendo ruído, como também aplicada à psicologia sensorial para avaliar a capacidade de indivíduos distinguirem ou não a existência de estímulos (METZ, 1986). Posteriormente, ocorreu a sua aplicação nas áreas de diagnósticos médicos, avaliação da desigualdade de renda, previsão de tempo, chegando, por último, ao campo da aprendizagem por máquina, sendo aplicada na análise de classificadores (BRADLEY, 1997).

ROC é uma ferramenta robusta utilizada para visualizar, avaliar e comparar o desempenho entre modelos de classificação, sendo possível ainda determinar o ponto de decisão (x_c – valor de corte) que melhor discrimina distribuição de uma característica em duas classes, ou seja, entre distribuições dos resultados positivos e negativos, além de ser possível determinar o melhor classificador simplesmente determinando área sob a curva ROC (AUC do inglês: *Area Under ROC Curve*).

A AUC é uma medida que expressa a capacidade intrínseca de classificador descriminar uma amostra qualquer pertencente ou não a uma determinada classe, onde a AUC determina a acurácia do classificador.

A curva ROC é expressa através de gráfico, onde o eixo das abscissas corresponde a (*1-especificidade*) e o eixo das ordenadas equivale à *sensibilidade*, compondo assim um plano unitário, cuja área máxima abaixo da curva é igual 1, obtido apenas em classificadores ideais.

De acordo com Metz (1978), a sensibilidade é a probabilidade de um sistema detectar os casos verdadeiros positivos, conhecida também como taxa de verdadeiros positivos (TPR do inglês: *True Positive Rate*), e a especificidade, de detectar os casos verdadeiros negativos, também conhecida como taxa de verdadeiros negativos (TNR do inglês: *True Negative Rate*), conforme equações (4) e (5), respectivamente.

Sensibilidade =
$$TPR = \frac{\text{Números de Decisões Verdadeiros Positivos}}{\text{Total de Casos Positivos}} = \frac{TP}{TP + FN}$$
 (4)

Especificidade =
$$TNR = \frac{N \hat{u}$$
meros de Decisões Verdadeiros Negativos
Total de Casos Negativos = $\frac{TN}{TN + FP}$ (5)

A Figura 8a ilustra um caso hipotético de um classificador A, dada uma variável x, a qual é transformada em dicotômica: positivo f(x|P) e negativo f(x|N), de acordo com limiar de decisão. Este classificador pode cometer um erro de tipo I ou tipo II, sendo que o tipo I consiste em classificar como positivo uma amostra negativa, ou seja, erro de falso positivo (FP). E o tipo II consiste em classificar como negativo uma amostra positiva, ou seja, erro de falso negativo (FN). O valor x_c indicado na Figura 8b, o ponto mais próximo para sensibilidade=especificidade=1 (canto superior esquerdo do gráfico), expressa o melhor compromisso entre sensibilidade e especificidade. No caso do classificador adotar o ponto de corte 1, o sistema será menos criterioso, classificando como positivas amostras que não têm

uma forte evidência de serem positivas, sugerindo então que a taxa de TP aumentará, enquanto que a taxa FP também aumentará.



Figura 8 – Curva ROC: (a) representação da distribuição f(x | P) e f(x | N); (b) representação dos pontos de corte indicados na Figura 8a e desempenho de três classificadores distintos por meio de suas curvas Fonte: Adaptado de Metz (1978)

Além disso, como mencionado anteriormente, é possível comparar o desempenho de classificadores distintos, calculando a área abaixo das suas respectivas curvas. A Figura 8b sugere que o classificador B tem melhor desempenho que o A que por sua vez é maior que o C. A área sob a curva ROC pode ser calculada de forma simples através da regra do trapézio (BRADLEY, 1997).
5 MATERIAIS E MÉTODOS

O sistema de reconhecimento de padrões de vazamento de gás natural proposto é baseado em seis etapas. A primeira etapa consiste da aquisição das imagens padrões da área poço, utilizando como sensor a câmera descrita na secção 5.1. A segunda, engloba a fase de pré-processamento dos dados coletados pelo sensor de imagem, e consiste da segmentação da cabeça do poço, ROI alvo do estudo, pois é onde pode ocorrer um vazamento de GN. Salienta-se que neste estudo o vazamento de GN. A terceira etapa consiste em extrair das imagens segmentadas, as componentes R, G, B, H, S e I (componentes dos espaços de cores RGB e HSI) e seleção das características de entrada dos classificadores a serem desenvolvidos na quarta etapa, sendo o que distingue um classificador do outro é a componente dos espaços de cores (R, G, B, H, S ou, I) que forma a base do classificador em questão.

Na quarta etapa, é apresentada ao classificador uma imagem, que a classifica como pertencente a uma das classes: imagem sem vazamento de GN ou imagem com vazamento de GN. Em seguida, nas imagens classificadas como pertencentes ao grupo de imagens com vazamento, é determinada a região onde ocorreu o vazamento. Por último, quantifica-se o tamanho da área correspondente ao vazamento. O diagrama de blocos da Figura 9 ilustra as etapas citadas.



Figura 9 - Diagrama em blocos do sistema de reconhecimento de padrões de vazamento de gás natural

Nesse capítulo são apresentadas as etapas de metodologia mostradas na Figura 9.

5.1 AQUISIÇÃO DAS IMAGENS

O método proposto para detecção de vazamento de GN é aplicado às imagens obtidas por meio do CCTV oriundas da câmera Yokogawa®, conforme mostrado na Figura 10. O elemento sensor CCD dessa câmera dispõe de uma resolução espacial 320 x 240 *pixels*, sendo que esse equipamento possui de sistema iluminação infravermelho (IR, do inglês: *Infrared*), o qual também é objeto de estudo na detecção de vazamento de GN com reduzidos níveis de iluminação natural.



Figura 10 – Modelo de câmera existente na área do poço petrolífero Fonte: Yokogawa (2012)

O CCTV trata-se de um sistema já existente, no qual a câmera está instalada na área do poço a uma distância de quinze metros da cabeça do poço, sendo esta distância necessária, uma vez que o equipamento de imagem não possui características adequadas que o permita ser operado em áreas classificadas¹.

A Figura 11 ilustra os itens mencionados no parágrafo anterior, apresentando o cenário real na qual as imagens foram coletadas.



Figura 11 – Área do poço petrolífero e sistema de aquisição de imagens

¹ Área potencialmente explosiva, devido à existência de gases, líquidos, poeiras e ou vapores inflamáveis, exigindo precauções especiais para a construção, instalação e utilização de equipamento elétrico.

Como mencionado no início desta seção, as imagens contendo vazamento são oriundas de simulação de vazamentos de gás natural, por meio da abertura de uma válvula agulha, que é utilizada como ponto de tomada para retirada de amostra de gás, localizada na cabeça do poço. Visando evitar acidentes ou danos ao meio ambiente, o volume de GN liberado nas simulações de vazamento foi o mínimo necessário para coleta dos dados a serem aplicados neste estudo.

Além da câmera Yokogawa® foram utilizados outros *hardwares* para aquisição das sequencias de quadros de imagens (vídeo). Em virtude de a câmera dispor o sinal nos padrões NTSC (*National Television System Committee*) e PAL (*Phase Alternating Line*) foi empregado uma placa de captura de vídeo MSI® VOX[™] USB, conforme Figura 12, cuja resolução máxima é 720x480 *pixels*, sendo então estes vídeos armazenados em notebook Panasonic® Toughbook S9 que dispõem das seguintes configurações: processador Intel® i5-520M Core[™], memória RAM de 2 GB e HD de 320 GB.



Figura 12 - Sistema de captura de vídeos

A aquisição das imagens ocorreu entre os dias 17 a 24 de outubro de 2012, durante este período diversos vídeos foram capturados em diversas circunstâncias do cenário, totalizando 01h12min44s (uma hora, doze minutos e quarenta e quatro segundos), sendo que a resolução dos vídeos é 320x240 *pixels*.

Após analisar o conteúdo dos vídeos gravados ficou constatado que alguns vídeos eram redundantes com relação a sua contextualização e tipo de cenário, os quais foram descartados deste estudo, sendo reduzido o tempo de gravação para 25min31s (vinte e cinco minutos e trinta e um segundos).

A partir destes vídeos foi extraído um conjunto formado por 3.060 imagens, construído por dois subconjuntos ou duas classes, sendo 2.000 imagens da classe sem vazamento e 1.060 imagens da classe com vazamento, conforme Tabela 5.

Classe	Total de Imagens por Classe
SEM VAZAMENTO	2.000
COM VAZAMENTO	1.060
Total	3.060

Tabela 5 - Conjunto de imagens obtidas da área do wellhead

Essas imagens constituíram a base vetorial dos filtros de novidade, bem como foram utilizadas na fase de testes e validação.

No intuito de tornar os filtros de novidade robustos, capturou-se imagens com os mais diversos cenários, incluindo imagens diurnas e noturnas e com ruídos, tais como chuva e presença de pessoas. Esse conjunto de imagens formou a base de treinamento dos filtros de novidade, aumentando assim a memória auto-associativa desses filtros e, consequentemente, o poder de classificação dos mesmos.

Assim as situações, os cenários e tipos de imagens que foram capturas e selecionadas são as seguintes:

- a. Classe sem vazamento, imagens:
 - Diurnas, livres de ruídos;
 - Diurnas com a presença de pessoas em diversas posições e quantidades na área do *wellhead*;
 - Diurnas com precipitação pluviométrica (chuva);
 - Diurnas com presença de pessoas e chuva;
 - Noturnas, livres de ruídos e iluminação sem IR;
 - Noturnas, com pessoas e sem iluminação IR;
 - Noturnas, com IR.

A Tabela 6 apresenta o resumo dos tipos de imagens e suas respectivas quantidades, que formam a classe de imagens sem vazamento, composta por 2.000 imagens.

Classe	Período	Ruído / Situação	Total de Imagens
		Sem Ruído	500
	D'	Com Pessoas	250
	Diurno	Com Chuva	250
SEM VAZAMENTO		Com Chuva e Pessoas	250
		Sem Ruído e Sem IR	250
	Noturno	Com Pessoas e Sem IR	250
		Com IR	250
	2.000		

Tabela 6 – Subconjunto de imagens que constituem a classe: sem vazamento

- b. Classe com vazamento, imagens:
 - Diurnas, livres de ruídos;
 - Diurnas com a presença de pessoas em diversas posições e quantidades na área do *wellhead*;
 - Diurnas com precipitação pluviométrica (chuva);
 - Diurnas com presença de pessoas e chuva;
 - Noturnas, livres de ruídos e com iluminação IR;
 - Noturnas, com pessoas e iluminação IR;

A Tabela 7 apresenta o resumo dos tipos de imagens e suas respectivas quantidades que formam a classe de imagens com vazamento, composta por 1.060 imagens.

Classe	Período	Ruído / Situação	Total de Imagens
		Sem Ruído	250
	Diurno	Com Pessoas	200
COM VAZAMENTO		Com Chuva	250
COM VAZAMENTO		Com Chuva e Pessoas	60
	Noturno	Sem Ruído e Com IR	200
	noturno	Com IR e Pessoas	100
	1.060		

Tabela 7 - Subconjunto de imagens que constituem a classe: com vazamento

5.2 PRÉ-PROCESSAMENTO

Nesta etapa as 3.060 imagens (conjunto global) foram segmentadas, dentro do cenário de 320x240 *pixels*, a região de interesse que englobem apenas a área compreendida pela árvore de natal, no intuito de reduzir falsos positivos oriundos de regiões que contenham nuvens do "céu" que são "similares" ao vazamento de gás natural, assim como reduzir os ruídos provocados pela vegetação presente, conforme exemplificado Figura 13a.

Como a câmera que capturou as imagens é fixa, ao ser aplicado um *offset* X1, Y1, X2, Y2 a uma imagem do conjunto global, o mesmo *offset* pode então ser replicado às demais imagens do conjunto global de imagens sem danos ao filtro de novidade. Diante desta situação determinaram-se os pontos de *offset* apresentado na Figura 13b, de tal forma a reduzir ao máximo possível à quantidade de vegetação presente na ROI, assim como o céu, o que resultou na ROI da Figura 13c, cuja dimensão é 184x160 *pixels*, tal redução foi replicada as demais imagens do conjunto global utilizando uma rotina desenvolvida no Matlab®.



(a)





Figura 13 – Segmentação da ROI: (a) imagem original da área do poço, (b) *offsets* aplicado na imagem original e (c) ROI resultante.

5.3 EXTRAÇÃO DE CARACTERÍSTICAS

O sistema desenvolvido neste estudo busca determinar qual das componentes relacionadas aos espaços de cores RGB e HSI que melhor classifica um vazamento de gás natural.

A câmera do CCTV fornece imagens no espaço de cores RGB, favorecendo assim a extração das matrizes correspondentes as componentes R, G e B, posteriormente através de rotina desenvolvida no Matlab®, são extraídas as demais matrizes referentes as componentes H, S e I do espaço de cor HSI.

Portanto, a partir dessas seis componentes R, G, B, H, S e I é possível formar seis distintos filtros de novidades, sendo que o que diferencia um filtro do outro é justamente a componente com a qual o filtro de novidade foi treinado, ou seja, a componente que forma a sua base.

Logo, a partir desde ponto de trabalho os filtros de novidades passaram a receber a seguinte nomenclatura:

- Filtro de novidade R, cuja base é formada pela componente R do espaço do RGB;
- Filtro de novidade G, cuja base é formada pela componente G do espaço do RGB;
- Filtro de novidade B, cuja base é formada pela componente B do espaço do RGB;
- Filtro de novidade H, cuja base é formada pela componente H do espaço do HSI;
- Filtro de novidade S, cuja base é formada pela componente S do espaço do HSI;
- Filtro de novidade I, cuja base é formada pela componente I do espaço do HSI;

Consequentemente, a Tabela 6 passa a ser complementada com as componentes de RGB e HSI, conforme apresentado na Tabela 8.

Classa	Doríodo	Ruído /	Total de	Filtro de Novidade					
Classe	renouo	Situação	Imagens	R	G	В	Н	S	Ι
		Sem Ruído	500	500	500	500	500	500	500
		Com Pessoas	250	250	250	250	250	250	250
	Diurno	Com Chuva	250	250	250	250	250	250	250
SEM		Com Chuva e Pessoas	250	250	250	250	250	250	250
VAZAMENTO		Sem Ruído e Sem IR	250	250	250	250	250	250	250
	Noturno	Com Pessoas e Sem IR 250		250	250	250	250	250	250
		Com IR	250	250	250	250	250	250	250
	2.000	2.000	2.000	2.000	2.000	2.000	2.000		

Tabela 8 – Subconjunto de imagens/componentes que constituem a classe de imagens sem vazamento

O mesmo ocorre com a Tabela 7, sendo complementada com as componentes de RGB e HSI, conforme apresentado na Tabela 9.

Classe	Período	Ruído /	Total de	Filtro de Novidade					
		Situaçao	Imagens	R	G	В	Н	S	Ι
		Sem Ruído	250	250	250	250	250	250	250
		Com Pessoas	200	200	200	200	200	200	200
	Diurno	Com Chuva	250	250	250	250	250	250	250
COM VAZAMENTO		Com Chuva e Pessoas	60	60	60	60	60	60	60
	Natara	Sem Ruído e Com IR	200	200	200	200	200	200	200
	Noturno	Com IR e Pessoas	100	100	100	100	100	100	100
Total de Imagens da Classe: COM VAZAMENTO		1.060	1.060	1.060	1.060	1.060	1.060	1.060	

Tabela 9 - Subconjunto de imagens / componentes que constituem a classe de imagens com vazamento

5.4 CLASSIFICADOR BASEADO EM FILTRO DE NOVIDADE

Para cada uma das características (R, G, B, H, S e I) foi desenvolvido um filtro de novidade específico, como mencionado na seção anterior. Independente das características (componente que constitui a base do filtro de novidade), a aplicação do filtro de novidade para detectar vazamentos de GN compreende os seguintes passos:

- Compor um conjunto original de *m* dados da componente Y (R, G, B, H, S ou I) pertencentes a classe sem vazamento de GN. Estes dados são utilizadas para formar os *m* vetores {x₁, x₂,...x_m}, do filtro de novidade Y (R, G, B, H, S ou I);
- O conjunto de vetores {x₁, x₂,...x_m} será obtido conforme descrito por Costa e seus colaboradores (2011);
- 3. Na sequência, os vetores $\{\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_m\}$ são submetidos à equação (2) (treinamento), a fim de se obter os vetores ortogonais $\{\mathbf{v}_1, \mathbf{v}_2, ..., \mathbf{v}_m\}$, cujo procedimento foi previamente descrito na seção 4.1;
- 4. Dado um vetor {x}, sua componente "novidade" é calculada como o passo (m+1) do processo descrito na etapa (2), ou seja, x̃ = v_{k+1}, tal como descrito na equação (3). Sendo que a magnitude do vetor x̃, ||x̃||, é usada como medida de

dissimilaridade. Quanto menor a magnitude do vetor \tilde{x} , mais próximo será para a base $\{v_1, v_2, ..., v_m\} \in \mathbb{R}^n$, ou seja, a partir do valor de $\|\tilde{x}\|$ a imagem será classificada como contendo ou não vazamento de GN.

Seguindo esta metodologia, na formação da base do filtro de novidade R foram utilizadas as componentes R da classe sem vazamento, na base do filtro de novidade G foram utilizadas as componentes G da classe sem vazamento, e assim por diante para os demais filtros de novidade (B, H, S e I), conforme mencionado na seção 5.3.

A seguir é apresentada a metodologia para obtenção do melhor valor de limiar de classificação, que é baseado no valor de $\|\tilde{x}\|$, como também a metodologia adotada para determinar o desempenho dos classificadores, ambas desenvolvidas por meio de rotinas no Matlab®.

5.5 METODOLOGIAS PARA TREINAMENTO E TESTE.

Para alcançar o objetivo de identificar qual componente dos espaços de cores (RGB e HSI) produz um classificador com o melhor desempenho é necessário definir uma metodologia para treinamento e teste. Alguns cuidados devem ser tomados ao se projetar os conjuntos de treinamento e teste no sentido de obter resultados confiáveis de desempenho. Um primeiro cuidado é o de não utilizar o mesmo conjunto de treinamento para realizar os testes do classificador. Nesse caso o desempenho do algoritmo será demasiadamente otimista, sendo esta falha conhecida como "taxa de erro aparente".

Outra situação que também pode mascarar o desempenho do algoritmo é quando após a etapa de testes e obtenção do desempenho inicial de um algoritmo, são realizadas modificações nos parâmetros do algoritmo no intuito de melhorar esse desempenho, e posteriormente são realizadas uma nova bateria de testes com o mesmo conjunto utilizado no teste inicial (antes das modificações no algoritmo). Nesse contexto, o que se procura é tão somente aperfeiçoar o desempenho do classificador frente ao conjunto de teste. Assim, podese afirmar que o conjunto de teste "passa" a fazer parte também do treinamento do algoritmo, O ideal é que se mudem os conjuntos de treinamento e teste sempre que houver alteração dos parâmetros do algoritmo.

Para o treinamento e teste diversas metodologias podem ser utilizadas quanto a utilização dos dados disponíveis. Supondo que estejam disponíveis n amostras para

treinamento e teste. Quando o número *n* é pequeno utiliza-se a metodologia "deixa uma de fora" (*leave-one-out*), que consiste em treinar o classificador com *n-1* amostras e testar com *1* amostra que ficou de fora do treinamento. Repete-se esse processo *n* vezes e depois se extrai um valor de desempenho médio. Quando *n* é grande pode-se utilizar a metodologia "metade-metade" (*holdout*), que consiste em utilizar metade dos dados para treinamento e metade dos dados para teste. No caso intermediário, utiliza-se a metodologia de "validação-cruzada" (*cross-validation*). Nessa última metodologia, separa-se uma parte dos dados para teste. Com esses percentuais, o processo é repetido 5 vezes. No final obtém-se um valor de desempenho médio (BOWYER, 2000).

Este trabalho adotou-se a metodologia metade-metade em virtude quantidade significativa de imagens (3.060 imagens) que formam o conjunto global de imagens padrões.

5.5.1 Método Metade-Metade ou Holdout

De posse dos conjuntos de dados, conforme apresentados nas Tabelas 8 e 9, o banco de dados de cada componente foi dividida randomicamente em duas partes iguais, formando então dois subconjuntos A e B. Logo para cada componente haverá dois filtros de novidade, por exemplo, o filtro de novidade R, foi treinado com uma base constituída pela metade A das imagens da componente R sem vazamento e o outro filtro treinado com uma base constituída pela metade B das imagens da componente R sem vazamento de GN.

A etapa seguinte ao treinamento, o teste de um filtro de novidade consistiu em realizar o treinamento com o conjunto A e testar este filtro com o conjunto B. Outro classificador foi treinado com o conjunto B e testado o conjunto A. Então, dado o desempenho (AUC) dos dois classificadores é calculada a média entre eles e definido o desempenho global do classificador, conforme ilustrado na Figura 14.



Figura 14 – Diagrama de blocos do método de formação dos conjuntos de treinamento e testes do filtro de novidade Fonte: Adaptado de Bowyer (2000, p. 584)

Pela definição ilustrada na Figura 14, o banco de dados das Tabelas 8 e 9 foram divididos em dois grupos (A e B), conforme apresentado na Tabela 10.

<u>د</u> ه	•		Filtro de Novidade											
asse	íod	Ruído /	l	R	(r T	I	3	I	I	5	5]	[
Ū	Per	Situação	Α	В	Α	В	Α	В	Α	В	Α	В	Α	В
		Sem Ruído	250	250	250	250	250	250	250	250	250	250	250	250
	rno	Com Pessoas	125	125	125	125	125	125	125	125	125	125	125	125
ento	Diu	Com Chuva	125	125	125	125	125	125	125	125	125	125	125	125
azam		Chuva e Pessoas	125	125	125	125	125	125	125	125	125	125	125	125
em V		Sem Ruído e Sem IR	125	125	125	125	125	125	125	125	125	125	125	125
Š	Noturno	Com Pessoas e Sem IR	125	125	125	125	125	125	125	125	125	125	125	125
		Com IR	125	125	125	125	125	125	125	125	125	125	125	125
		Sem Ruído	125	125	125	125	125	125	125	125	125	125	125	125
to	no	Com Pessoas	100	100	100	100	100	100	100	100	100	100	100	100
amen	Diu	Com Chuva	125	125	125	125	125	125	125	125	125	125	125	125
ı Vaz		Com Chuva e Pessoas	30	30	30	30	30	30	30	30	30	30	30	30
Con	IIIIO	Sem Ruído e Com IR	100	100	100	100	100	100	100	100	100	100	100	100
	Noti	Com IR e Pessoas	50	50	50	50	50	50	50	50	50	50	50	50
		Total	1530	1530	1530	1530	1530	1530	1530	1530	1530	1530	1530	1530
		1 0 tui	3.0)60	3.0)60	3.0)60	3.0)60	3.0)60	3.0)60

Tabela 10 - Divisão do banco de dados da componente em dois grupos: A e B

5.6 DESEMPENHO DO CLASSIFICADOR

Aplicando os conceitos da curva ROC aos seis filtros de novidade, o limiar de decisão, $\|\tilde{x}\|$, foi incrementado em passos de 0,02, entre o intervalo [0,1] constituindo então 51 limiares.

Para cada um desses 51 diferentes limiares foram obtidos seus respectivos valores de TP, FN, TN e FP, e a partir desses calculadas as taxas de sensibilidade e especificidade através das equações (4) e (5).

Em seguida, utilizando os valores de sensibilidade e especificidade, foram construídas duas curvas ROC para cada filtro de novidade, conforme ilustrado na Figura 15, sendo então calculada a área sob cada curva (AUC) utilizando a regra do trapézio.

O desempenho global de cada filtro de novidade foi determinado calculando-se a média aritmética da AUC das duas curvas do respectivo filtro, conforme equação (6).

$$D_{FILTROY} = \frac{1}{2} \sum_{i=A}^{B} AUC(Y_i)$$
(6)

O próximo passo foi definir o melhor ponto de corte (x_c) em todas as doze curvas ROC, que segue a seguinte lógica: seis filtros de novidade e cada filtro possui duas curvas ROC, totalizando doze curvas. O limiar x_c indicado na Figura 8b, é o ponto da curva ROC mais próximo ao ponto TPR=TNR=1, ou seja, aquele que possuir a menor distância até o ponto TPR=TNR=1, sendo o melhor ponto de corte do classificador, conforme elucidado na Figura 15.



Figura 15 – Curva ROC: determinação do melhor x_c

Portanto, dada uma curva ROC, para todos os pontos $[TPR(x_c), TNR'(x_c)]$ determinados pela variação do limiar x_c foi calculada a distância destes pontos até o ponto TPR=TNR=1, através da equação (7), o x_c que obteve a menor distância foi considerado a limiar ótimo para filtro de novidade em questão.

Distancia
$$(x_c) = \sqrt{(1 - TNR(x_c))^2 + (1 - TPR(x_c))^2}$$
 (7)

Como foram construído para uma mesma componente dois filtros de novidade, consequentemente há duas curvas ROC e dois x_c ótimos: x_c ótimo da curva ROC do Grupo A e outro x_c ótimo da curva ROC do Grupo B. O x_c global da componente foi determinado aplicando uma média simples aos dois x_c (Grupo A e Grupo B).

Outras informações podem ser obtidas a partir da tabela de confusão (Tabela 4) e curva ROC para se determinar a variabilidade do classificador, tal como o erro médio relativo dentre outras métricas (BOWYER, 2000). Neste trabalho foi utilizado o erro padrão (SE, do inglês: *Standard Error*) da AUC (HANLEY e MCNEIL, 1982), referente ao desvio padrão em virtude da acurácia=AUC= θ e o tamanho da amostra utilizada nos testes do classificador, amostra esta constituída por uma quantidade de amostras sem vazamento ou normais (n_N) e outra por amostra com vazamento ou anormais (n_A) . A partir destas informações foi determinado o erro padrão de cada curva ROC por meio das equações (8), (9) e (10).

$$Q_1 = \frac{\theta}{\left(2 - \theta\right)} \tag{8}$$

$$Q_2 = \frac{2 \cdot \theta^2}{(1+\theta)} \tag{9}$$

$$SE = \sqrt{\frac{\theta \cdot (1-\theta) + (n_A - 1) \cdot (Q_1 - \theta^2) + (n_N - 1) \cdot (Q_2 - \theta^2)}{n_A \cdot n_N}}$$
(10)

Onde, Q_1 corresponde à probabilidade de duas imagens anormais, escolhidas aleatoriamente serem classificadas com maior suspeição do que uma imagem normal aleatoriamente escolhida, e Q_2 corresponde à probabilidade de uma imagem anormal, escolhida aleatoriamente ser classificada com maior suspeição do que duas imagens normais aleatoriamente escolhidas (HANLEY E MCNEIL, 1982).

Após a coleta e análise dos resultados de desempenho foi desenvolvido o sétimo e oitavo filtro de novidade, ambos baseados na componente R tendo como base de treinamento o grupo B. No sétimo filtro de novidade, cuja nomenclatura é filtro de novidade R1, foram excluídas da fase de teste as imagens noturnas com vazamento. Já no oitavo filtro de novidade, cuja nomenclatura é filtro de novidade R2, foram excluídos dos testes as imagens noturnas com e sem vazamentos, e então foi avaliado a resposta de ambos os filtros via curva ROC e demais métricas.

5.7 ESTUDO SOBRE EXISTÊNCIA DE CORRELAÇÃO LINEAR ENTRE O NÍVEL DE VAZAMENTO REAL E O DETECTADO NA IMAGEM

Como mencionado anteriormente, a simulação dos vazamentos de gás natural ocorreu por meio da abertura de uma válvula agulha, utilizada como ponto de tomada para retirada de amostra do gás, localizada na árvore de natal. A jusante desta tomada e montante foram instalados dois instrumentos indicadores e transmissores de pressão diferencial, os quais forneceram o volume de gás liberado durante os testes.

Após definido o melhor classificador, diversas imagens contendo diversos níveis de vazamento foram apresentadas a este classificador, o qual segmentou a ROI contendo o vazamento, conforme descrito na seção 4.1.4.

Posteriormente, para cada imagem contendo níveis diferentes de vazamento foi realizada contagem de todos os *pixels* da ROI classificados como "com vazamento". Os resultados da contagem de *pixels* foram comparados com o volume do GN liberado durante a simulação de vazamento, e estes resultados serão apresentados no decorrer desta dissertação.

6 RESULTADOS E DISCUSSÕES

Este capítulo está organizado da seguinte forma: na primeira seção são mostrados todos os resultados decorrentes da utilização do filtro de novidade para detecção de vazamento de GN e demais objetivos explanados ao longo desta dissertação. E a segunda seção versa sobre a discussão dos resultados obtidos.

6.1 RESULTADOS

6.1.1 Base de dados utilizada

Conforme descrito nas Tabelas 6 e 7, em diversas condições e cenários foram capturadas as imagens da área do *wellhead*, a fim de se construir uma base de treinamento sólida, mediante o incremento de mais informações à memória auto-associativa do filtro de novidade, já mencionado na seção 5.1 desta dissertação.

Conforme já colocado na metodologia, nesse trabalho foram usadas imagens diurnas e noturnas, com ou sem a presença de ruídos, constituídos de chuva e presença de pessoa humana. A Figura 16 apresenta alguns destes cenários.



Figura 16 – Amostra de imagens coletadas da área do poço: (a) diurna livre ruído, (b) noturna livre de ruído e sem IR, (c) noturna com vazamento e IR, (d) diurna com chuva, (e) diurna com chuva e vazamento, (f) diurna com vazamento, (g) diurna sem vazamento e com pessoa e (h) diurna com chuva e pessoa

A maior dificuldade encontrada na aquisição das imagens foi em sincronizar a disposição do profissional habilitado para executar as simulações dos vazamentos e a equipe

responsável pelas gravações com as condições climáticas adequadas, pois durante os dias de gravação as precipitações pluviométricas que ocorreram na região do poço foram de curta duração, em compensação em todos os dias houve chuva. Outro ponto de atenção foi à impossibilidade de aquisição de imagens sob a seguinte configuração: com vazamento, período noturno e iluminação artificial visível ao ser humano, pois nesta configuração haveria o risco de acidentes em virtude do refletor não ser adequado para área classificada. Entretanto, foi possível capturar as imagens nesta configuração substituindo o refletor em questão pelo refletor IR, instalado em área não classificada.

O banco de imagens foi composto por 3.060 imagens e de cada imagem foi extraída a região de interesse e suas respectivas componentes R, G, B, H, S e I. A Figura 17 ilustra a extração da ROI e suas componentes referente a Figura 16a.



Figura 17 – Componentes R, G, B, H, S e I extraídas da imagem 17(a): (a) componente R, (b) componente G, (c) componente B, (d) componente H, (e) componente S e (f) componente I.

6.1.2 Resultados dos filtros de novidade R, G, B, H, S, I, R1 e R2

Como mencionado na metodologia do treinamento, os dados de cada componente foram divididos randomicamente em duas partes iguais, formando então dois subconjuntos (A e B) conforme Tabela 10. Consequentemente há duas curvas ROC para cada filtro de novidade. Portanto, nesta seção são apresentados os resultados obtidos em cada filtro de novidade.

6.1.2.1 Da distribuição de especificidade e sensibilidade dos filtros de novidades

Conforme explanado na fundamentação, a formação da curva ROC se dá mediante os dados de especificidade e sensibilidade obtidos em função da variação do *limiar*.

Os gráficos das Figuras 18a e 18b apresentam a distribuição de especificidade e sensibilidade fornecidos pelo filtro de novidade R, sendo que primeiro gráfico é referente ao filtro de novidade R treinado pelo subconjunto A e testado pelo subconjunto B, e o segundo treinado pelo subconjunto B e testado pelo subconjunto A.



Figura 18 – Distribuições de especificidade e sensibilidade do Filtro de Novidade R de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B

Seguindo o raciocínio do parágrafo anterior, os gráficos das Figuras 19a e 19b, Figuras 20a e 20b, Figuras 21a e 21b, Figuras 22a e 22b, Figuras 23a e 23b, Figuras 24a e 24b e Figuras 25a e 25b, apresentados a seguir são referentes à distribuição de especificidade e sensibilidade fornecidos pelos dos filtros de novidade G, B, H, S, I, R1 e R2, respectivamente.



Figura 19 – Distribuições de especificidade e sensibilidade do Filtro de Novidade G de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B



Figura 20 – Distribuições de especificidade e sensibilidade do Filtro de Novidade B de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B



Figura 21 – Distribuições de especificidade e sensibilidade do Filtro de Novidade H de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B



Figura 22 – Distribuições de especificidade e sensibilidade do Filtro de Novidade S de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B



Figura 23 – Distribuições de especificidade e sensibilidade do Filtro de Novidade I de acordo com o grupo que formou a base do filtro: (a) base formada pelo grupo A e (b) base formada pelo grupo B



Figura 24 – Distribuições de especificidade e sensibilidade do Filtro de Novidade R1: base formada pelo grupo B, excluídas dos testes as imagens noturnas com vazamento



Figura 25 – Distribuições de especificidade e sensibilidade do Filtro de Novidade R2: base formada pelo grupo B, excluídas dos testes as imagens noturnas com e sem vazamento

6.1.2.2 Do desempenho dos filtros de novidade R, G, B, H, S, I, R1 e R2

Depois de constituídos os valores de especificidade e sensibilidade a apresentados na seção 6.1.2.1 desta dissertação, foram traçadas as curvas ROC de cada filtro de novidade proposto.

Os gráficos que serão apresentados a seguir foram formados pela sobreposição das duas curvas ROC do filtro de novidade em análise. Nos gráficos também são fornecidos limiares ideais de cada curva e o limiar global do filtro, assim como a AUC de cada curva e a AUC global do filtro de novidade em questão.



Figura 26 - Desempenho do Filtro de Novidade R: curvas ROC do grupo A e B da componente R



Figura 27 - Desempenho do Filtro de Novidade G: curvas ROC do grupo A e B da componente G



Figura 28 - Desempenho do Filtro de Novidade H: curvas ROC do grupo A e B da componente B



Figura 29 - Desempenho do Filtro de Novidade G: curvas ROC do grupo A e B da componente H



Figura 30 - Desempenho do Filtro de Novidade S: curvas ROC do grupo A e B da componente S



Figura 31 - Desempenho do Filtro de Novidade I: curvas ROC do grupo A e B da componente I

Alguns resultados adicionais foram obtidos, procurando avaliar o efeito das imagens noturnas, excluindo dos testes as imagens noturnas. Para obtenção do gráfico apresentado na Figura 32 retirou-se do grupo de imagens de teste as imagens noturnas com vazamento. Para obtenção do gráfico apresentado na Figura 33 retirou-se do grupo de imagens de teste as imagens noturnas com e sem vazamento.



Figura 32 - Desempenho do Filtro de Novidade R1: curvas ROC do grupo B da componente R, excluídas dos testes as imagens noturnas com vazamento de GN



Figura 33 - Desempenho do Filtro de Novidade R2: curva ROC do grupo B da componente R, excluídas dos testes as imagens noturnas com e sem vazamento de GN

6.1.2.3 Do resumo do desempenho dos filtros de novidade R, G, B, H, S, I, R1 e R2

A Tabela 11 retrata as informações das métricas obtidas em cada filtro de novidade, por meio de suas respectivas curvas ROC.

		Grupo de	treinament	0			
Filtro de Novidado	Gru	іро А	Gru	upo B	Limiar módio do Filtro	AUC	
noviuaue	Limiar	AUC	Limiar	AUC		meuta do Filito	
R	0,08	99,253 %	0,06	97,802 %	0,07	98,527 %	
G	0,10	97,828 %	0,08	97,273 %	0,09	97,550 %	
В	0,10	77,110 %	0,08	78,626 %	0,09	77,868 %	
Н	0,28	66,918%	0,28	64,260 %	0,28	65,589 %	
S	0,54	28,571 %	0,16	69,956 %	0,35	49,264 %	
Ι	0,10	98,813 %	0,08	98,065 %	0,09	<i>98,439 %</i>	
R1			0,08	98,955%			
R2			0,08	98,919%			

Tabela 11 - Resumo das métricas de desempenho dos filtros de novidade R, G, B, H, S, I, R1 e R2

A última coluna da Tabela 11 expressa a AUC global (acuraria média do filtro de novidade) em função da componente utilizada pelo filtro, sendo determinada a partir da

equação (6). Já a penúltima coluna desta tabela é referente ao valor médio do *limiar* obtido a partir da média aritmética dos limiares do Grupo A e Grupo B, sendo que para o filtro R1 e R2 não há valores médios de limiar e AUC, já que esses filtros são baseados apenas no Grupo B, conforme será elucidado nas análises.

Após determinados os melhores limiares de decisão nas curvas ROC, foram obtidos os valores de sensibilidade e especificidade de acordo com esses limiares de decisão, com base nas distribuições de especificidade e sensibilidade apresentada na seção 6.1.2.1, estes valores estão tabulados na Tabela 12.

Filtro de Novidade	Grupo da base	Limiar	Sensibilidade (TPR)	Especificidade (TNR)	TPR-TNR
D	А	0,08	0,961	0,969	0,008
K	В	0,06	0,923	0,951	0,028
C	А	0,10	0,944	0,959	0,015
U	В	0,08	0,925	0,958	0,033
D	А	0,10	0,687	0,814	0,127
В	В	0,08	0,676	0,997	0,321
Ц	А	0,28	0,540	0,730	0,190
п	В	0,28	0,542	0,696	0,154
ç	А	0,54	1,000	0,285	0,715
3	В	0,16	0,563	0,845	0,282
T	А	0,10	0,966	0,940	0,026
1	В	0,08	0,940	0,912	0,028
R1	В	0,08	0,965	0,957	0,008
R2	В	0,08	0,961	0,957	0,004

Tabela 12 – Especificidade e sensibilidade dos filtros de novidade R, G, B, H, S, I, R1 e R2

6.1.2.4 Do erro padrão das curvas ROC dos filtros de novidade R, G, B, H, S, I, R1 e R2

Aplicando as informações contidas na Tabela 11 às equações (8), (9) e (10) foi possível determinar o erro padrão (SE) dos classificadores, conforme apresentado na Tabela 13. Ressalta-se que os valores de n_N e n_A , utilizados para calcular SE, foram 1.000 (imagens sem vazamentos) e 530 (imagens com vazamentos) referente ao tamanho das classes sem vazamento e com vazamento, respectivamente.

		Grupo de t	AUC				
Filtro de Novidade	Gruj	po A	Gruj	ро В	média do	SE global do Filtro*	
itoridade	AUC	SE	AUC	SE	Filtro	uo 1 111 0	
R	99,253 %	0,2651%	97,802 %	0,4532%	98,527 %	0,3717%	
G	97,828 %	0,4505%	97,273 %	0,5041%	97,550 %	0,4781%	
В	77,110 %	1,3342%	78,626 %	1,3011%	77,868 %	1,3180%	
Н	66,918%	1,4921%	64,260 %	1,5170%	65,589 %	1,5053%	
S	28,571 %	1,3067%	69,956 %	1,4558%	49,264 %	1,5490%	
Ι	98,813 %	0,3339%	98,065 %	0,4255%	98,439 %	0,3825%	
R1			98,955%	0,3134%			
R2			98,919%	0,3187%			

Tabela 13 - Erro padrão dos filtros de novidade: SE por grupo de treinamento (A e B) e SE global do filtro*

* Calculado a partir das equações (8), (9) e (10), utilizando a AUC média do Filtro.

6.1.3 Segmentação do vazamento de GN nas imagens classificadas como pertencentes à classe com vazamento

Após constatação do desempenho dos filtros de novidade, apresentou-se diversas imagens da classe com vazamento ao filtro de novidade R (base formada pelas imagens do grupo A. Conforme esperado, o filtro as classificou como pertencentes a classe com vazamento. Seguindo a fundamentação apresentada na seção 4.1.4, essas imagens foram binarizadas, segundo o seguinte critério: os *pixels* pertencentes à classe sem vazamento assumiram o valor 0 e os *pixels* pertencentes a classe com vazamento o valor 1, conforme ilustrado na Figura 34.



Figura 34 – Segmentação do vazamento: (a) imagem diurna, (b) imagem 35a binarizada; (c) imagem noturna; (d) imagem 35c binarizada; (e) imagem noturna com pessoas; (f) imagem 35e binarizada; (g) imagem com chuva; (h) imagem 35g binarizada

6.1.4 Correlação entre vazamento e quantidade de *pixels* classificados como pertencentes a classe com vazamento

Durante as simulações de vazamento de GN o nível de gás liberado para atmosfera foi registrado através dos instrumentos indicadores de pressão diferencial, sendo então coletadas as imagens durante os níveis de vazamento: 0,25; 0,50; 0,75; e 1,0 litro/hora. Estas imagens foram apresentadas ao filtro de novidade R (grupo A), o qual segmentou e classificou os *pixels* pertencentes à classe com vazamento, conforme amostras apresentadas na figura 35.



Figura 35 – Segmentação do vazamento em diferentes níveis de vazamento de GN, expressos em litros / hora: (a) 0.75, (b) 0.50, (c) 0.25 e (d) 1.0

A Tabela 14 expressa o total de *pixels* das imagens da Figura 35 determinado pelo classificador como pertencentes à classe com vazamento, sendo que estes resultados serão discutidos na seção discussões.

Nível do vazamento (litros/hora)	Total de <i>pixels</i> Com vazamento	Imagem de referência Figura 35
0,25	7.660	(a)
0,50	9.141	(b)
0,75	7.405	(c)
1,00	8.546	(d)

Tabela 14 - Nível do vazamento e quantidade de pixels classificados como com vazamento

6.2 ANÁLISE E DISCUSSÃO DOS RESULTADOS

6.2.1 Das distribuições de especificidade e sensibilidade

A partir dos limiares de decisão (Tabela 12) obtidos pelas curvas ROC foi possível constatar que o filtro de novidade R (Grupo A) possui a melhor dessemelhança entre especificidade, com valor de 0,969, e sensibilidade, com valor de 0,961, resultando na diferença de 0,008. Logo, este filtro possui TNR>TPR. Esta característica pode ser considerada prejudicial quando se trata em detectar vazamentos de gás natural, pois este classificador está propenso a cometer o erro tipo II, ou seja, erro de falso negativo (FN).

O filtro de novidade G (Grupo A) possui a segunda maior diferença entre especificidade (0,959) e sensibilidade (0,944) resultando na diferença de 0,015. Quando comparados os valores de especificidade e sensibilidade deste filtro com o filtro de novidade R (Grupo A), em ambas as características TPR e TNR, o filtro de novidade R (Grupo A) é superior.

O terceiro melhor filtro foi o filtro de novidade I (Grupo A) com elevada diferença TPR-TNR=0,026, baixa especificidade (0,940), e sensibilidade com valor de 0,966, cometendo o erro de classificação do tipo I, o que no contexto do problema pode ser aceitável quando se trata de detectar um vazamento de gás natural, pois ele classifica como positivas imagens que não contêm vazamento.

Normalmente, as características de sensibilidade e especificidade são antagônicas, o que torna difícil elevar a capacidade do classificador em detectar os casos TP sem prejudicar o poder do classificador em detectar os casos TN, pois a sensibilidade e especificidade são inversas, o que significa que à medida que aumenta a sensibilidade, a especificidade diminui e vice-versa (PARIKH, *et al.* 2008).

Entretanto, esta proporcionalidade entre sensibilidade e especificidade pode não ser linear, fato este constatado na distribuição de especificidade e sensibilidade do filtro de novidade S, ilustrada nas Figuras 22a e 22b, onde se constatou que entre os limiares de decisão 0,24 e 0,54 a especificidade se manteve constate enquanto a sensibilidade aumentou. Tal fato culminou para a curva ROC do filtro de S (grupo A) se manter próximo ao eixo das abscissas, resultando um valor de AUC=28,57%.

Conforme definido por Hanley e McNeil (1982), área sob a curva ROC (AUC) mede a probabilidade das anormalidades serem corretamente identificadas, em um conjunto de imagens aleatórias.

Portanto, após determinadas as curvas ROC dos filtros de novidade R, G, B, H, S e I ilustradas nas 6.1.2.3, e suas respectivas métricas transcritas na Tabela 11, foi possível determinar que o filtro de novidade que melhor classifica um vazamento de gás natural, entre os demais, é filtro de novidade R, pois este filtro apresentou o maior valor médio de AUC = 98,527%, que os demais filtros propostos.

O segundo melhor filtro de novidade é o filtro I com AUC=98,439%, seguido pelos filtros G com AUC=97,55%, filtro B com AUC=77,868%, filtro H com AUC=65,589% e por fim com AUC=49,264% o filtro S.

Ao se avaliar os filtros de novidade por grupo de treinamento (A e B), verificou-se que não houve mudança de posição dos filtros de novidade do Grupo A, sendo que o filtro de novidade R obteve AUC=99,253%, seguido pelo filtro I com AUC=98,813%, G com AUC=97,828%, filtro B com AUC=77,11%, filtro H com AUC=66,918% e filtro S com AUC=28,571%.

Apesar do baixo valor da AUC do filtro S, este filtro tem um valor de dessemelhança maior que o filtro H, quando analisado o complementar da AUC de S, ou seja, AUC'=1-AUC=71,429%. Entretanto, este filtro inverte a decisão, ou seja, ao apresentar uma imagem com vazamento ele a classifica como sem vazamento, o mesmo ocorre para uma imagem sem vazamento, que ele a classifica como com vazamento. Logo, se a decisão do filtro S for invertida o mesmo terá uma acurácia de 71,429%.

Já no grupo B, a ordem dos filtros foi alterada, quanto ao seu poder de decisão. O melhor filtro de novidade foi o filtro I com AUC=98,065%, seguido do filtro R com AUC=97,802%, filtro G com AUC=97,273%, filtro B com AUC=78,626%, filtro S com AUC=69,956% e por fim filtro H com AUC=64,26%. Logo, analisando os filtros em termos do grupo B de imagens que foram a base de treinamento destes classificadores, o filtro de novidade I (Grupo B) possui uma AUC (desempenho) maior que filtro de novidade R (Grupo B).

Diante desde dilema, os erros das curvas de ambos os grupos (A e B) de todos os filtros foram calculados e expressos na Tabela 13. No Grupo A, os dois filtros que apresentam menor erro padrão (SE) são os filtros de novidade R e I, sendo que SE(R)=0,2651% e SE(I)=

0,3339%, respectivamente. E no grupo B, os dois filtros que apresentam menor erro padrão (SE) também são os filtros de novidade R e I, com SE(R)= 0,4532% e SE(I)= 0,4255%, respectivamente. Aplicando a média simples aos erros do filtro R e I, observou-se que o erro padrão médio do filtro de novidade R é $\overline{SE(R)}$ = 0,00359%, enquanto do erro do filtro de novidade I é $\overline{SE(I)}$ = 0,00379%, ou seja, o erro do filtro I é maior que o R.

Ainda assim foi calculado o erro global destes dois filtros utilizando a AUC global de cada filtro aplicada às equações (8), (9) e (10), resultando em SE(I)=0,3825% > SE(R)=0,3717%.

Portanto, por esses subsídios científicos, admitisse que o Filtro de Novidade R é o que melhor classifica vazamentos de gás natural em imagens digitais.

6.2.3 Do desempenho do filtro de novidade R, excluídas as imagens noturnas dos testes

Após definido o melhor classificador, no caso o filtro de novidade R, buscou-se avaliar qual o impacto das imagens noturnas no desempenho deste filtro. Como o filtro de novidade R (Grupo A) possui elevada eficiência (AUC=99,253%), fez-se uso do filtro de novidade R (Grupo B), cujo poder de dissimilaridade é AUC=97,802%.

O primeiro experimento consistiu na redução da quantidade do banco de imagens teste, mantendo a mesma base treinamento. Neste experimento, as imagens noturnas com vazamento foram suprimidas do conjunto de testes. Com isso o valor de AUC(R Grupo B) que era 97,802% passou para AUC(R1)=98,955% e consequentemente o erro que era de SE(R Grupo B)=0,4532%, foi reduzido para SE(R1)=0,3134%.

O segundo experimento foi similar ao primeiro, sendo excluídas dos testes as imagens noturnas sem vazamento como também as noturnas com vazamento, resultando em AUC(R2)=98,919% e SE(R2)=0,3187%.

Constata-se então, que as imagens noturnas induzem na redução da eficiência do classificador, ou seja, houve um ganho de eficiência excluindo as condições noturnas. Outro fato que deve ser elucidado, é que a AUC(R1)>AUC(R2). A princípio pode ser entendido como uma falha do classificador, tendo em vista que, a quantidade de imagens noturnas a serem classificadas foi reduzida mais no filtro R2, entretanto o filtro de novidade R (Grupo B) possui especificidade (0,951) maior que sensibilidade (0,923). Isso torna o classificador mais rígido a classificar imagens sem vazamento, e como as imagens noturnas sem vazamento

possuíam "muito ruído" estas eram classificadas como TN mais facilmente que as imagens sem ruído.

6.2.4 Da segmentação do vazamento nas imagens

Nos vazamentos apresentados nas Figuras 34a a 34h é possível constatar que o filtro de novidade R possui a capacidade de identificar os *pixels* pertencentes à classe com vazamento. Entretanto, nesta fase de segmentação o sistema mostrou não ser imune a ruídos, como por exemplo: na Figura 34e há uma pessoa na área do poço, na segmentação dos *pixels* desta imagem, conforme resultado na Figura 34f, o braço do operador foi classificado como pertencente à classe com vazamento. Este fato poderia ser uma falha de maior magnitude se fosse apresentada uma imagem sem vazamento e o filtro em questão a classificasse como com vazamento. Em consequência ele segmenta como vazamento um ruído que não era vazamento. Entretanto, o filtro de novidade R demonstrou ser robusto na classe sem, como na com vazamento de GN.

6.2.5 Da existência de correlação entre vazamento e quantidade de *pixels* classificados como pertencentes à classe com vazamento

O sistema proposto não é capaz de fazer uma correlação linear entre o nível de vazamento de GN presente na atmosfera com a quantidade de *pixels* classificados como pertencentes à classe com vazamento, conforme apresentado na Tabela 14, onde, por exemplo: a quantidade de *pixels* classificados como vazamento para uma vazão de 0,50 litros/hora (total de 9.141 de *pixels* com vazamento) foi maior que para uma vazão 1,00 litros/hora (total de 8.546 de *pixels* com vazamento).

O motivo da inexistência desta correlação linear pode estar relacionado às condições climáticas e as propriedade físico-químicas do gás natural em contato com atmosfera, pois além do GN ser menos denso que o ar, ele tem a propriedade de expansibilidade². Agregado a estes fatores a direção do vento e sua velocidade fazem que o mesmo volume de gás forneça uma nuvem de GN de diferentes tamanhos e direções, sendo incapaz um sistema de visão de duas dimensões (2D) determinar o real tamanho da nuvem de gás presente no ambiente.

² Capacidade do gás de aumentar seu volume quando submetido à variação de pressão.

7 CONCLUSÕES

Tanto por questões econômicas, como pela segurança das pessoas envolvidas em atividades petroquímicas, a detecção de vazamento de gás natural é de grande importância para indústria petrolífera. Neste contexto, este trabalho teve por objetivo principal contribuir com a literatura da área, apresentando uma nova técnica de detecção de vazamento de gás natural por meio de um sistema de reconhecimento de padrões baseado em filtro de novidade aplicado a imagens digitais.

Para tanto, foram testados seis tipos distintos de filtros de novidade, cuja diferença entre estes filtros está no tipo de componente dos espaços de cores RGB e HSI utilizado na formação da base de treinamento dos respectivos filtros.

Com base nas análises comparativas objetivas que foram realizadas em termos de AUC e SE, constatou-se que entre as componentes R, G, B, H, S e I, a que melhor caracteriza um vazamento de GN é a componente R, apresentando a acurácia média de 98,527% e erro padrão de 0,3717%, sendo o que o filtro de novidade R, cuja base foi formada pelo Grupo A de imagens, obteve especificidade e sensibilidade máxima de 0,969 e 0,961, respectivamente, e AUC=99,253%.

Entretanto, não foi possível comparar o desempenho do filtro de novidade R com outros sistemas de detecção de vazamento de gás natural, pois a literatura dispõe de sistemas de detecção de vazamento de gás natural pontuais, sendo que o sistema desenvolvido nesta dissertação tem a capacidade de detecção de forma global, ou seja, detectando o vazamento em qualquer área da imagem. Deve-se salientar que, ao localizar as regiões onde ocorreram o vazamento nas imagens "com vazamento", o sistema proposto, segmentou áreas onde não ocorreu o evento, ou seja, para esta finalidade o sistema apresentou falso positivos.

Adicionalmente, com o modelo desenvolvido, ou seja, filtro de novidade R estabelecido como melhor classificador, foi avaliado a sua robustez nas imagens noturnas, percebendo-se que, nessas imagens, a eficácia do classificador diminui em 1,153 %, em virtude da AUC(R Grupo B)=97,802% e AUC(R1 Grupo B)=98,955%.

Não é recomendada a aplicação deste método para quantificar o vazamento de gás natural liberado para atmosferas, pois os resultados apurados revelem que o mesmo não tem capacidade de quantificar ou estimar o nível do vazamento.

Sugere-se que trabalhos futuros sejam desenvolvidos, com o intuito de realizar avaliações estatísticas para se determinar o nível de interferência que cada tipo de ruídos provoca no classificador. Um campo de estudos interessante que se apresenta é a possibilidade de inclusão de um filtro de novidade específico para condições de baixos níveis de iluminação natural.

Outra importante análise seria aplicar outros métodos de processamento digital de imagem e reconhecimento de padrões para detectar vazamento de gás natural sobre as mesmas condições aqui estudadas e comparar o desempenho entre estes sistemas.

REFERÊNCIAS BIBLIOGRÁFICAS

BOWYER, K. W. Validation of Medical Image Analysis Techniques. In: SONKA, M. and , FITZPATRICK, J. M. **Handbook of Medical Imaging**, SPIE, v. 2, p. 567-607, Washington-USA, 2000.

BRADLEY, A. P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. Original Research Article Pattern Recognition, v. 30, ed. 7, p. 1145-1159, jul. 1997.

BRASIL. Lei n. 11.909, de 04 de março de 2009. Dispõe sobre as atividades relativas ao transporte de gás natural, de que trata o art. 177 da Constituição Federal, bem como sobre as atividades de tratamento, processamento, estocagem, liquefação, regaseificação e comercialização de gás natural; altera a Lei no 9.478, de 6 de agosto de 1997; e dá outras providências. Disponível em < http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/111909.htm>. Acessado em: 18 abr. 2012.

BRASIL. Ministério de Minas e Energia (MME). Balanço Energético Nacional (BEN)
2011. Rio de Janeiro: Empresa de Pesquisa Energética (EPE), 2011. Disponível em: < https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2011.pdf>. Acesso em: 18 abr. 2012.

COBB, Cathy; GOLDWHITE, Harold. **Creations of Fire**: Chemistry's Lively History from Alchemy to the Atomic Age. New York: Plenum Press, 1995 Cambridge: Perseus Publishing, 1995.

CORRÊA, O. L. S. **Petróleo**: Noções sobre Exploração, Perfuração, Produção e Microbiologia. Rio de Janeiro: Interciência, 2003.

CORTELETTI, R. C. **Desenvolvimento de metodologia para concepção de traçados de dutos de transporte de gás natural.** 2009. Dissertação (Mestrado) - Programa de Pós-Graduação Em Geotécnica, Escola de Minas, Universidade Federal de Ouro Petro, Minas Gerais, 2007.

COSTA FILHO, C. F. et al. Applying a novelty filter as a matching criterion to iris recognition for binary and real-valued feature vectors. Journal Signal, Image and Video Processing, v. 5, p. 1-10, Springer London, 2011.

COSTA FILHO, C. F.; MELO, R.O.; COSTA, M.G.F. **Detecting natural gas leaks using digital images and novelty filters**. Lecture Notes in Artificial Intelligence Series, n. 7326, p. 242-249, Heidelberg: Springer, 2012.

COSTA, M. G. F.; MOURA, L. Automatic assessment of scintmammographic images using a novelty filter. Proceedings of the 19th Annual Symposium on Computer Applications in Medical Care, p. 537–41, São Paulo, 1995.

CULLEN Lord, W. D. The public Inquiry into the Piper Alpha Disaster, Londres: HMSO Books, nov. 1990.

DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern Classification. Wiley- Interscience Publication, 2000.

EGIG - EUROPEAN GAS PIPELINE INCIDENT DATA GROUP. Gas pipeline incidents. 8th Report of the European Gas Pipeline Incident Data Group, 2011. Disponível em: http://www.egig.eu. Acessado em: 10 fev. 2012.

ELSIMARY, Hamed. Implementation of neural network and genetic algorithms for novelty filters for fault detection. IEEE 39th Midwest symposium on Circuits and Systems, v. 3, p. 1432-1435, Cairo, 1996.

FAN, Z.; TAISHAN, L.; LIPING, Z. **BP Neural Network Modeling of Infrared Methane Detector for Temperature Compensation**. Proceedings of 8th International Conference on Electronic Measurement & Instruments, p. 4123-4126, Xian, 2007.

FIRTH, J. G.; JONES, A.; JONES, T. A. **The principles of the detection of flammable atmospheres by catalytic devices**. Journal Combustion and Flame, v. 21, n. 3, p. 303-311. 1973 FORBES, R. J. Bitumen and Petroleum in Antiquity, Leiden: E. J. Brill, 1936.

GOLD, Thomas. The origin of natural gas and petroleum, and the prognosis for future supplies. Ann. Rev. Energy, n. 10, p. 53-77, 1985.

HALTSONEN, S. et al. Application of Novelty Filter to Segmentation of Speech. Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP'78 p. 565-568, abr. 1978.

HANLEY, J. A; MCNEIL B.J. The meaning and use of the area under a Receiver Operating Characteristic (ROC) curve. Radiology, v. 143, n. 1, p. 29-36, abr. 1982.

HUSEYNOV, J. et al. Gas-leak localization using distributed ultrasonic sensors. 16th SPIE Conference on Smart Sensor Phenomena, Technology, Networks, and Systems II, San Diego, v. 7293, mar. 2009.

IEA - INTERNATIONAL ENERGY AGENCY. **Key World Energy Statistics 2011**. Disponível em: http://www.iea.org/textbase/nppdf/free/2011/key_world_energy_stats.pdf> Acessado em: 01 mar. 2012.

KASTEK, M. et al.. Methane detection in far infrared using multispectral IR camera. Proceedings of 9th International Conference on Quantitative Infrared Thermography, p. 1-4. Krakow, Poland, 2008.

KASTEK, M. et al. Methane detection in far infrared using multispectral IR camera. Institute of Optoelectronics, Military University of Technology, S.Kaliskiego 2. Warsaw, Poland, 2008.

KOHONEN, T.; OJA, E. Fast adaptive formation of orthogonalizing filters and associative memory in recurrent networks of neuron-like elements. In: Biological Cybernetics (BIOL CYBERN), v. 25, n. 2, p. 85-95. Berlin: Springer-Verlag, 1976.

KOHONEN, T. Self-Organization and Associative Memory. ed. 3rd, Berlin, Germany: Springer-Verlag, 1989.
KOVACS, M. G. The Epic of Gilgamesh. Stanford University Press, Stanford. Tablet XI. 1990.

KRIER, A.; SHERSTNEV, V. V. **Powerful interface light emitting diodes for methane gas detection.** Journal of Physics D: Applied Physics, v. 33, n. 2, p. 101-106, 2000.

MCCAIN, W. D. The properties of petroleum fluids.: ed. 2 Oklahoma: Penn Well Books, 1990.

MCRAE, T. G.; KULP, T. J. **Backscatter absorption gas imaging**: a new technique for gas visualization. Journal of the Optical Society of America, Applied Optical, v. 32, p. 4037-4050, jul. 1993.

METZ, C. E. **Basic Principles of ROC Analysis**. In: Seminars in Nuclear Medicine, v. 8, n. 4, p. 283-298, 1978.

METZ, C. E. Statistical Analysis of ROC Data in Evaluating Diagnostic Performance. In: D HERBERT, D. E.; MYERS, R. H. **Multiple Regression Analysis**: Applications in the Health Sciences, n. 13, 365–384, 1986.

NEEDHAM, J. et al. Science and Civilization in China, Volume 4, Part II, Cambridge University Press, 1965.

PRATI, R. C.; BATISTA, G. E. A. P. A.; MONARD, M. C. **Curvas ROC para avaliação de classificadores**. IEEE Latin América Transactions, v.6, n.2, p. 215-222, 2008.

PARIKH, R. et al. **Understanding and using sensitivity, specificity and predictive values.** Indian Journal of Ophthalmology, vol. 56, n.4, p.341, 2008.

RAFF, U.; NEWMAN, F. D. Lesion Detection in Radiologic Images Using an Autoassociative Paradigm: Preliminary Results. Medical Physics, p. 926–928, 1990.

ROBBINS, W. K.; HSU, C. S. **Petroleum Composition.** Kirk-Othmer Encyclopedia of Chemical Technology, p. 1-17, 2000. Disponível em: http://dx.doi.org/10.1002/0471238961. 0315131618150202.a01>. Acessado em: 06 de fev. de 2012.

ROSS, C. E. H.; SOLAN, L. E. : **Terra Incognita**: A Navigation Aid for Energy Leaders. Oklahoma: Penn Well Corporation, 2007.

SLOAN, E. D. Fundamental principles and applications of natural gas hydrates. Nature, n. 426, p. 353-363, nov. 2003.

SOVACOOL, B. K. **The cost of failure**: a preliminary assessment of major energy accidents, 1907–2007. Energy Policy, n. 36, p. 1802–1820, 2008.

SOUZA, C. A. V.; FREITAS, C. M. Perfil dos acidentes de trabalho em refinaria de petróleo. Revista de . Saúde Pública, v. 36, n. 5, p. 576-583, São Paulo, 2002.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4 ed. San Diego, California, USA, Academic Press, 2009.

THOMAS, J. E. Fundamentos de Engenharia do Petróleo. ed. 2 Rio de Janeiro: Interciência, 2004.

TISSOT, B. P.; WELTE, D. H. **Petroleum Formation and Occurrence.** ed. 2 New York and Berlin: Springer-Verlag, 1984.

VINNEM, J. E. Evaluation of offshore emergency preparedness in view of rare accidents. Journal Safety Science, v. 49, n. 2, p. 178-191, fev. 2011.

WHITICAR, M. J. Correlation of natural gases with their sources. In: MAGOON, L; DOW,W. The Petroleum System: From Source to Trap, American Association Of Petroleum Engineers, p. 261-283, 1994.

WU, Y.; CARROLL, J. J. A Review of Recent Natural Gas Discoveries in China.Conference Sour Oil & Gas Advanced Technology (SOGAT), p. 113-129, Abu Dhabi, abr.2008.

YOKOGAWA. **General Specifications:** FC15U (Outdoor) CCD Color Camera. Disponível em: < http://www.yokogawa.com/itv/products/itv-fc15-en.htm>. Acessado em: 15 de abr. de 2012.

ZABETAKIS, M. G. **Flammability characteristics of combustible gases and vapors**. In: Bulletin 627, Bureau of Mines, Washington: U.S. Government Printing Office, 1965.

APÊNDICE A – TRABALHOS PUBLICADOS

- Título: "Detecting natural gas leaks using digital images and novelty filters", apresentado na International Conference on Autonomous and Intelligent Systems (AIS, 2012) e publicado na revista Springer: Lecture Notes in Artificial Intelligence Series, v. 7326, p. 242-249, 2012.
- Título: "Aplicação do filtro de novidade de Kohonen para detecção de vazamento de gás natural", publicado nos anais de *IV Petroleum and Chemical Industry Conference*, p. 1-6, Rio de Janeiro, 2012.

Detecting natural gas leaks using digital images and novelty filters

Roberlanio de Oliveira Melo¹, Cícero Ferneira Fernandes Costa Filho^{1,*}, Marly Guimarães Fernandes Costa¹

¹ Centro de Tecnologia Eletrônica e da Informacao, Universidade Federal do Amazonas, Amazonas Brasil

roberlanio@yahoo.com.br,cccsta@gmail.com,

marly.costa@uol.com.br

Abstract. This paper presents a new technique for detecting natural gas leaks in the oil and gas industry. More precisely, the detection is done in wellheads of industry installations. In the literature, other methods are already used, but with some drawbacks. One technique detects gas leaks measuring the CH_4 concentration through the principle of catalytic combustion but suffers from reduced life span and a narrow detection range of sensors. Another technique that measures infrared spectrum absorption suffers from high false negative values in the presence of steam. The technique proposed in this study uses radiation in the visible range that can be captured through CCD cameras already present in *Closed-Circuit Television* systems used to monitor wells. The proposed method uses the novelty filter concept to detect the leak and to identify the region where it occurs. The proposed technique is a pioneering study of natural gas detection with CCD in visible range. The results presented are promising, showing sensitivity and specificity equal to 100%.

Keywords: detection of natural gas leak, novelty filter, gas and oil industry

1 INTRODUCTION

The oil and gas industry is one of the most complex and dangerous fields due to intrinsic characteristics of hydrocarbons, such as: toxicity, inflammability and explosion velocity [1]. The occurrence of gas leaks in oil installations generates undesirable financial and environmental consequences, and loss of human lives [2]. Constant monitoring is necessary to avoid these undesirable consequences and there is a great demand for the development of new systems for monitoring and controlling gas leaks.

Petroleum is a mixture of hydrocarbons in a solid, liquid or gaseous state, in standard temperature and pressure, according to molecule complexity and weight. Natural gas is a byproduct of the petroleum found in a gas phase, being composed of a mixture of several hydrocarbons, whose molecules are in the form C_nH2_{n+2} , for n

varying between one and four. Among the hydrocarbons present in natural gas, about 70% is methane (*CH*₄), which presents a lower and upper limit of inflammability of 5% and 15%, respectively, and minimum ignition energy of $250\mu J$ [3]. Several methods used to detect natural gas are based on detecting the methane leak to the atmosphere. In the sequence, we give some examples of them.

The Safety in Mines Research Establishment (SMRS) [4] proposed the principle of catalytic combustion to measure the CH_4 concentrations present in the environment. This principle is based on temperature rises resulting from the heat generated from methane combustion in a catalytic surface employing the palladium as a sensor element. Due to ease in manufacturing and low cost, this device has been used for many years, until presently. These sensors, nevertheless, have a reduced life span and a narrow detection range [5].

The analysis of infrared spectrum absorption (IR) has been used more frequently in methane detection. The main reasons are: the IR detector has a life span of more than five years, stability and reliability. An IR detection system is comprised of an IR transmitter and receptors with electromagnetic spectrum $\lambda_{\rm tR} = 2 \sim 5 \mu m$. When IR radiation interacts with methane gas ($\lambda_{\rm CH_4} \approx 3.5 \mu m$), a part of the energy is absorbed and the remaining energy is transmitted [6]. The energy absorbed increases the vibration of methane molecules and, consequently, increases the temperature of the gas. The gas concentration is obtained through the measure of the ratio between the incident and transmitted radiation [5]. The main drawbacks of this system include difficulties in installing and maintaining and the high false negative values in the presence of steam, because the IR radiation is also absorbed by this substance.

Another technique used increasingly in detecting natural gas leaks is digital image processing. In 1997, the U.S. Department of Energy (DOE) together with Sandia of National Laboratories to National Security Missions [7] proposed a system called Backscatter Absorption Gas Imaging (BAGI), whose basic principle was to illuminate a gas leak scenario, applying an IR laser, and then photograph this leakage using an IR camera. Systems employing this technology are very expensive [8-9], achieving values of US 80,000 when used for a single inspection, but not for continuous inspection.

Usually natural gas leaks appear to human beings as a white cloud or fog, because when the methane comes into contact with the atmosphere, its low temperature induces air condensation [10]. Considering this fact, this study proposes a natural gas detection method in wellheads of an onshore petroleam installation using a *Closed-Circuit Television* system with *Charge-Coupled Device* (CCD) cameras to monitor wells located in forest areas. As these systems are already available, no additional expense is necessary for hardware implementation.

The idea explored in this study was to use a technique known as a novelty filter [11] to investigate the presence of a natural gas leaks in digital images captured by CCD canteras.

This paper is organized according to the following sections: sections 2 and 3 describe the novelty filter concept and application for detecting natural gas leaks, respectively. Section 4 presents the results and discussion. Finally section 5 presents the conclusion.

2 NOVELTY FILTER CONCEPT

The Novelty filter concept was described by Kohonen [11]. In this sequence, the novelty concept is described based on the classic orthogonalization method of Gram-Schmidt [12-13].

Let $\{x_1, x_2, \dots, x_m\}$ be a set of n dimensional Euclidian vectors which span a m dimensional subspace $L \subset \mathbb{R}^n$, with m < n. Considering the subspace L, an arbitrary vector $x \in \mathbb{R}^n$ can be divided into two components, \hat{x} and \hat{x} , where: $\hat{x} \in L$ is the projection of x on L and $\hat{x} \perp L$ is the projection of x perpendicular to L. Vector $\hat{x} \in L$ represents the component of x that is "known" by the subspace L and can be represented as a linear combination of $\{x_1, x_2, \dots, x_m\}$. Vector $\hat{x} \perp L$ represents the new information, that is unknown by the subspace L and can be new information of $\{x_1, x_2, \dots, x_m\}$. Vector $\hat{x} \perp L$ represented as a linear combination of $\{x_1, x_2, \dots, x_m\}$. Vector $\hat{x} \mid x^3$ space.



Fig. 1. - Illustration of novelty filter concept in \mathbb{R}^3 space

Thus, considering subspace L, \tilde{x} is named novelty and the system that extracts this component from x and shows it as an output can be named the Novelty Filter.

To determine the components \hat{x} and \hat{x} of a vector x, the Gram-Schmidt orthogonalization process was used, described as follows. Considering that we have a set of *m* independent vectors $\{x_1, x_2, ..., x_m\}$, the L basis. From this set, we can obtain m orthogonal vectors $\{v_1, v_2, ..., v_m\}$, through the procedure described in (1) and (2).

$$v_1 = x_1$$
 (1)

$$v_k = x_k - \sum_{i=1}^{k-1} \frac{(v_i v_k)}{(v_i v_i)}, v_i, k = 2, 3, \dots m$$
(2)

Where $\frac{\langle v_i, v_k \rangle}{\langle v_k, v_i \rangle}$, v_i is the projection of x_k on v_i .

Given a sample vector x, its novelty component is calculated as the (m + 1) step of the process described by (2), or $\tilde{x} = v_{k+1}$, as described in equation (3):

$$\tilde{x} = x - \sum_{l=1}^{m} \frac{(v_l x)}{(v_l v_l)}, v_l$$
 (3)

The magnitude of vector \tilde{x} , $\|\tilde{x}\|$, is used as a dissimilarity measure. The lower the magnitude of vector \tilde{x} , the closer it will be to the base $\{v_1, v_2, \dots, v_m\} \in \mathbb{R}^n$.

3 NOVELTY FILTER APPLICATION FOR DETECTING NATURAL GAS LEAKS

The images of the wellhead area are obtained through the system CFTV previously described, placing the CCD camera in a fixed position. The spatial resolution of the CCD sensor used was 352x240 pixels. This image is shown in Figure 2a, Inside this image, a *Region Of Interest* (ROI) closer to the wellhead was selected, with dimensions 128x128. The objective was to reduce the noise from trees and the sky and to concentrate the novelty filter focus on the *Christmas tree* of the wellhead, where the leaks are more frequent. An ROI with no natural gas leak is shown in Figure 2b, while an ROI with a natural gas leak is shown in Figure 2c. A set of 60 images with no natural gas leaks was obtained and another set with 30 images with natural gas leaks was also obtained. These images were used as described: two training image groups were formed, one of them, called group F_1 , with 20 images and the other, called group F_2 , with 30 images, both of them with no natural gas leaks. A test image set was formed comprised of 30 images with no natural gas leaks and of 30 images with natural gas leaks.



Fig. 2. - Images used in the study: (a) Original image; (b) ROI extracted close to the wellhead with no natural gas leak; (c) ROI extracted close to the wellhead with no natural gas leak

Applying the Novelty Filter to detect natural gas leaks comprises the following steps:

- Compose an original set of *m* ROI images with no natural gas leaks as those shown in Figure 2b. These images are used to form the *m* vectors {*x*₁, *x*₂, ..., *x_m*} of the novelty filter. To increase the robustness of the novelty filter, images with objects that eventually are present in the scene are included in the original set of images; For example, images with employees doing maintenance of the well were included.
 The set of vectors {*x*₁, *x*₂, ..., *x_m*] are obtained following the procedure described in [14]. All the images are converted to HSI color space. Then, for each one, an in-
- tensity matrix of 128x128 pixels is constructed containing the intensity component 1 of the HSI color space. In the sequence, each vector x_i corresponding to each im-

age is constructed concatenating the 128 columns of each intensity matrix, as shown in Figure 3. In this figure M=N=128, so the size of the vector is 16,384 components:



Fig. 3. - Vectors of characteristics using intensity levels of the images

 The set of orthogonal vectors {v₂, ..., v_m} is obtained following the procedure previously described in section 2;

 The novelty x for each image of the test set is then calculated following the procedure previously described in section 2.

Once the novelty filter detects that a natural gas leak is present in one image it is possible to highlight the region of the image where the leak occurs. In this study this region is called the novelty region. The process of highlighting this region adopted is described in the following steps:

1. Convert the novelty vector \hat{x} into a novelty matrix \hat{X} with dimensions 128x128;

- 2. Convert the novelty matrix \hat{X} into a novelty image with pixels in the range 0 to 255;
- 3. Apply a median filter to remove noise;
- Binarize the image applying a threshold with a value equal to an average image value.

The application of this process is illustrated in the next section.

4 RESULTS

As described in the previous section, two novelty filters were trained. The first one, novelty filter F_1 , using a base with 20 images and another, novelty filter F_2 , using a base of 30 images. The objective was to investigate the performance of the novelty filter when varying the number of images in the base.

After the training of the two novelty filters, the test images were evaluated. For each image test, the dissimilarity measure was calculated, the magnitude of the novel-ty, $\|\tilde{x}\|$. The range of values of the magnitude is defined as: $0 \le \|\tilde{x}\| \le 1$. As close as the magnitude $\|\tilde{x}\|$ is to 0, the likelihood of a natural gas leak is low. As close as the magnitude $\|\tilde{x}\|$ is to 1, the likelihood of a natural gas leak is high. In order to determine a threshold value to classify the images as having a leak or no leak, we used the Receiver Operating Characteristic (*ROC curve*) methodology, as proposed by Metz [15]. The *ROC curve* is traced with the horizontal axis representing the coordinate *1-specificity* and the vertical axis representing the coordinate sensitivity. The best operation point of an ROC curve is one situated at the upper and right side of the curve. This point corresponds to sensitivity = specificity = 1. The points used for curve tracing (1-specificity, sensitivity) were obtained varying the threshold between 0 and 1, with steps of 0.02. One ROC curve was traced for each novelty filter trained (base with 20 and with 30 images). Figure 4 shows these curves.



Fig. 4. ROC curves: (a) Novelty Filter F_1 (base with 20 images); (b) Novelty Filter F_2 (Base with 30 images)

Novelty filter F_1 correctly classified all 60 test images (30 with natural gas leak and 30 with no natural gas leak) with a threshold in the range: 0.3 < threshold < 0.38. In the extremes, *threshold* = 0.3, the sensitivity value was equal to 0.9 and the specificity was equal to 1, and, *threshold* = 0.38, the sensitivity value was equal to 1.0 and the specificity was equal to 0.93.

Novelty filter F_2 correctly classified all 60 test images with a threshold in the range: 0.3 < threshold < 0.34. In the extremes, threshold = 0.3, the sensitivity

value was equal to 0.9 and the specificity was equal to 1, and, threshold = 0.34, the sensitivity value was equal to 1.0 and the specificity was equal to 0.97.

Both novelty filters, F_1 and F_2 , reach an optimum performance, sensitivity = specificity = 1. The ranges that novelty filters present optimum performance (sensitivity=specificity=1), F_1 and F_2 , are nearly equal.

Figure 5 illustrates the steps of the process described in the previous section to highlight the novelty region. Figure 5a shows an original image with a natural gas leak. Figure 5b shows the novelty image. Figure 5c shows the image resulting from the application of a median filter. Figure 5d shows the binarized image with the novelty region (white pixels). The novelty region corresponds to the region where the natural gas leak occurs.

5 CONCLUSION

In this study a method was proposed for detecting natural gas leaks in a wellhead using images obtained with CCD cameras using the novelty filter concept. As cameras are already present in the *Closed-Circuit Television* system used to monitor the well, no additional expense is necessary for hardware implementation. The obtained results, sensitivity = 1 and specificity = 1 are promising and encourage new studies with the technique proposed herein. As this was a pioneering study of natural gas detection with CCD in the visible range, no other comparison can be made with the literature.

The following characteristics of the method are worth noting: the images must always be obtained in the same position and must be the same size.

Future studies will address the following questions: use a large base for the novelty filter, including other objects that may be present near the well; adapt the novelty filter to successful function with environmental changes, such as rain and lack of light (night). At night, a possibility is to employ IR illumination, which is also already available in *Closed-Circuit Television* systems used to monitor wells.



Fig. 5. - Detection of novelty region: (a) Original image; (b) Novelty image (c) Image resulting from median filter application; (d) Image showing novelty region

REFERENCES

- Souza, C.A.V., Freitas, C.M.: Perfil dos acidentes de trabalho em refinaria de petróleo. In: Rev. Saúde Pública, vol.36, no. 5, pp. 576-583. São Paulo (2002)
- Liu, H., Zhong S., et al.: Remote helicopter-borne laser detector for searching of methane leak of gas line. In: Prognostics and System Health Management Conference, vol., no., pp.1-5, IEEE, Shenzhen China (2011)
- Zabetakis, M.G.: Flammability characteristics of combustible gases and vapors. In: Bulletin 627, Bureau of Mines. U.S. Government Printing Office, Washington (1965)
- Firth, J.G., Jones, A. Jones, T.A.: The principles of the detection of flammable atmospheres by catalytic devices. In: Combustion and Flame, vol. 21, Issue 3, pp. 295-414 (1973)
- Fan, Z., Taishan, L., Liping, Z., et al.: BP Neural Network Modeling of Infrared Methane Detector for Temperature Compensation. In: Proceedings of 8th International Conference on Electronic Measurement & Instruments., ICEMI '07, vol., uo., pp. 4-123-4-126. Xi An, China (2007)
- Krier, A., Huang, X., et al.: Powerful interface light emitting diodes for methane gas detection. In: Journal of Physics D: Applied Physics, vol. 33, Issue 2, pp. 101-106 (2000)
- McRae, T.G., Kulp, T.J.: Backscatter absorption gas imaging: a new technique for gas visualization. In: Journal of the Optical Society of America, Applied Optical, vol. 32, pp. 4037-4050. USA (1993)
- Kastek, M., Sosnowski, T., et al. Methane detection in far infrared using multispectral IR camera. In: 9th International Conference on Quantitative Infrared Thermography, vol., no., pp. 1-4. Krakow, Poland (2008)
- Kastek, M., Sosnowski, T., et al. Methane detection in far infrared using multispectral IR caraera. In: Institute of Optoelectronics, Military University of Technology, S.Kaliskiego 2. Warsaw, Poland (2008)
- Ross, C.E.H., Solan, L.E. : Terra Incognita: A Navigation Aid for Energy Leaders. Penn-Well Corporation, Oklahoma, USA (2007)
- Kohonen, T., Oja, E.: Fast adaptive formation of orthogonalizing filters and associative memory in recurrent networks of neuron-like elements. In: Biological Cybernetics (BIOL CYBERN), vol. 25, no. 2, pp. 85–95. Springer-Verlag, Berlin (1976)
- Kohonen, T.: Self-Organization and Associative Memory. ed. 3rd. Springer-Verlag, Berlin-Heidelberg, New York-Tokyo (1989)
- Costa, M.G.F. Moura, L.: Automatic assessment of scintmammographic images using a novelty filter. In: Proceedings of the 19th Annual Symposium on Computer Applications in Medical Care, pp. 537–41. São Paulo (1995)
- Costa, P.F.F., et al.: Applying a novelty filter as a matching criterion to iris recognition for binary and real-valued feature vectors. In: Journal Signal, Image and Video Processing, vol. 5, pp. 1-10 Springer London (2011)
- Metz, C. E.; Basic Principles of ROC Analysis. In: Seminars in Nuclear Medicine, (Edition ENSP), vol. 8, no. 4, pp. 283-298, Elsevier (1978).

APLICAÇÃO DO FILTRO DE NOVIDADE DE KOHONEN PARA DETECÇÃO DE VAZAMENTO DE GÁS NATURAL

Copyright IEEE Trabalho PCIC BR 2012

Roberlânio de Oliveira Melo Mestrando em Engenharia Elétrica Universidade Federal do Amazonas Av. Ephigênio Sales, 100 Manaus, Amazonas Brasil lanio@yahoo.com.br

Dr. Cícero Ferreira F. Costa F. Doutor em Engenharia Elétrica Universidade Federal do Amazonas Av. General Rodrigo Otavio, 3000 Manaus Brasil o@gmail.com

1

Dra. Marly Guimarães F. Costa Doutora em Engenharia Elétrica Universidade Federal do Amazonas Av. General Rodrigo Otavio, 3000 Manaus Brasil marly.costa@uol.com.br

Resumo – Este trabalho apresenta um novo método de detecção de vazamento de gás natural em instalações petrofieras, especificamente em poços onshore, aplicando técnicas de reconhecimento de padres a imagens dígitais. Outros métodos de delecção de vazamento de gás natural, encontrados na literatura, têm como fundamento a análise encontrados na ilteratura, tem como fundamento a analise de moléculas de metano, seja aplicando o principio catalitico ou absorção de espectro infravermelho, estes apresentam algumas desvantagens como vida útil reduzida e condições de faisos negativos, respectivamente. O método proposto neste trabalho é baseado na aplicação do conceito de filtro neste tradamo e baseado na aplicação do concetto de titro de novidade em imagens digitais oriundas do sistema de *Closed-Circuit Television* para detecção de vazamento de gás natural. Os resultados preliminares obtidos são auspiciosos expressando sensibilidade e especificidade igual a 100%.

Palavras-chave — detecção de vazamento de gás, filtro de novidade, gás e indústria do petróleo.

I. INTRODUÇÃO

Nos dias atuais, o Gás Natural (GN) vem tomando lugar de Nos dias atuais, o Gás Natural (GN) vem tomando lugar de destaque como fonte de combustivel no mundo. Um dos principais motivos que favorece essa situação está relacionado a questões ambientais, pois o gás natural é um combustivel de queima limpa, produzindo menos dióxido de carbono quando comparado ao petróleo ou ao carvão [1]. De acordo com a infermational Energy Agency [2], entre os anos de 1973 e 2009, a produção mundial de gás natural aumentou 159,71%, ocupando neste último ano a terceira posição entre as maiores fontes de energia primárias produzidas no mundo, com 2.539,39 Mtep (milhões de toneladas equivalentes de petróleo).

posição entre as maiores fontes de energia primanas produzidas no mundo, com 2.539,39 Mtep (milhões de toneladas equivalentes de petróleo). Estudos da Empresa Pesquisa Energética do Brasil [3], entre os anos 2001 e 2010, revelam que houve um incremento de 63,9% na produção brasileira deste combustivel, tomando o gás natural responsavel por 10,3% da matriz energética do Brasil, refletindo os atuais 9.285 km de gasodutos instalados no território brasileiro. Apesar da evolução na produção e consumo dos derivados petrolíferos, a indústria mundial de petróleo e gás natural é um dos campos mais complexos e perigosos devido a características intrinsecas dos hidrocarbonetos, tais como: asfixia, inflamabilidade, energia mínima de ignição e velocidade de explosão [4]. Neste contexto, um dos acidentes de maior magnitude envolvendo este produto coorreu em 1988 na plataforma Piper Alfa [5], que operava no Mar do Norte próximo a Aberdeen. Após um vazamento de condensado de gás

natural para atmosfera e sua combustão, 167 vidas humanas foram perdidas e a plataforma ademou (6). Portanto, o constante monitoramento é necessário para

evitar essas consequências indesejáveis, havendo então uma grande demanda para o desenvolvimento de novos uma grande demanda para o desenvolvimento de novos sistemas para a monitoramente e controle de vazamento de gás natural. Sendo que diversos métodos para detecção de GN já foram desenvolvidos, em que na sua maioria se baseiam em detectar o vazamento de metano para atmosfera, pois o dentre os hidrocarbonetos que compõem o GN cerca de 70% é o metano. Em seguida são apresentados alguns dos métodos de detecção de vazamento GN já desenvolvidos. O Safety in Mines Research Establishment (SMRE) propôs o princípio da combustão catalítica para medir a concentração do CH₄ presente no ambiente [7]. Este princípio basei-as en o aumento da temperatura resultante do

concentração do CH_4 presente no ambiente [7]. Este principio baseia-se no aumento da temperatura resultante do calor gerado pela combustão do metano na superficie catalítica, empregando o paládio como elemento sensor. Devido à facilidade de fabricação e baixo custo, este tipo de dispositivo vem sendo utilizada até os dias atuais. Estes sensores, no entanto, têm vida útil relativamente reduzida e faixa de detecção estreita [8]. A análise sobre a absorção do espectro infravemelho (IR) também vem sendo utilizada com frequência na detecção do metano os principais motivos que levam à utilização deste método são os seguintes: o detector por IR tem vida útil superior a cinco anos; estabilidade e a confisibilidade. O sistema de detecção por IR é composto por transmissores e receptores de IR com espectro eletromagnético com a faixa de comprimento de onda situada em $\lambda_{tm} = 2 - s \mu m$. Quando a radiação IR interage com o gás metano, Quando a radiação IR interage com o gás metano, $\lambda_{CN_4} \approx 3.5 \mu m$, parte da energia é absorvida e o restante é

Arcy, e supuri, pane da circipa e dosarida e o restante e transmitida (9). A concentração de gás é obtida através da medida da razão entre a radiação incidente e a transmitida (8). Porém estes sistemas podem indicar alarmes de falsos negativos na presença de vapor de água, pois a radiação IR também é absorvida por esta substância. Considerando o fato que, normalmente, vazamentos de circa obtema de também de ta

Considerando o fato que, normalmente, vazamentos de gás natural bruto tornam-se visiveis ao ser humano em forma de uma nuvem branca ou neblina, pois o GN bruto ao entrar em contanto com a atmosfera induzir a condensação do ar ou em forma de aerossol [10] dependendo das condições de temperatura, pressão e umidade da atmosfera. Este trabalho propõe um método de detecção de vazamento de gás em poços de petróleo de uma instalação onshore utilizando o sistema de Closed-Circuit Television (CCTV) com Charge Coupled Device (CCD) que monitora a área do poço. A ideia explorada neste estudo é a utilização da técnica conhecida como filtro de novidade [11] para

investigar a presença de um vazamento de gás natural em imagens digitais capturadas por câmeras CCD, especificamente imagens da área da cabeça do poço (wel/head), as quais estão mais propensas a originar vazamento em virtude das inúmeras conexões e válvulas

que as compõe. Este trabalho está organizado da seguinte forma: o conceito de filtro de novidade e a metodologia adotada neste trabalho para aplicar o filtro de novidade na detecção de vazamento de GN são apresentados nas seções 2 e 3, respectivamente. A seção 4 expõe os resultados e discussão o for fim, observações finais são fornecidas na seção 8.

IL CONCEITO DE FILTRO DE NOVIDADE

Na literatura, inúmeros estudos em diversas áreas já foram desenvolvidos tendo como base a aplicação de filtro de novidade descrito por Kohonen e Oja em 1976 [11]. O leque de aplicação do filtro de novidade se expande da segmentação fonética [12], detecção de lesões de esclerose multipla em imagens de ressonância magnética [13], identificação de lesões em imagens cintilográficas de mamas [14], predição de memo real de falhas em equipamentos eléfricos [15], até o reconhecimento de indivíduos através da iris [16]. No entranto, é escasso o conteúdo literário no que eléficios (15), até o reconhecimento de individuos atraves da iris (16). No entanto, é escasso o conteúdo literário no que tange o processamento de sequência de imagens (video) utilizando o filtro de novidade, que é à base da proposta deste trabalho. O conceito de filtro de novidade foi descrito por Kohonen [11], como um tipo de memória auto-associativa. Nesta sequência, o conceito filtro de novidade é descrito com base es métodos de díseiro de otronna/ização de Gram-Schmidt

sequência, o conceito filtro de novoade e desura com vase no método dássico de ortogonalização de Gram-Schmidt [14], o qual pode ser utilizado na arquitetura de reconhecimento de padrões como um classificador,

Seja $\{x_1, x_2, ..., x_m\} \in \mathbb{R}^n$ um conjunto de vetores euclidianos de dimensão n que geram um subespaço $L \subset \mathbb{R}^{*}$ de dimensão m com m < n. Considerando o $L \subset \mathbb{R}^n$ de dimensão m com m < n. Considerando o subespaço L, um vetor arbitrário, $\mathbf{x} \in \mathbb{R}^n$, pode ser decomposto em duas componentes $\mathbf{t} \in \mathbf{X}$, onde $\mathbf{t} \in L$ e $\mathbf{X} \perp L$ que é a projeção perpendicular de \mathbf{X} em relação à L. O vetor $\mathbf{t} \in L$ representa a componente de \mathbf{X} que é conhecida" pelo subespaço L e pode ser representada pela combinação linear de $\{\mathbf{x}_{1}, \mathbf{x}_{2}, ..., \mathbf{x}_{n}\}$. O vetor $\mathbf{X} \perp L$ representa a informação "nova", que é "desconhecida" pelo subespaço L e não pode ser representado como uma combinação linear de $\{\mathbf{x}_{1}, \mathbf{x}_{2}, ..., \mathbf{x}_{n}\}$. A Fig. 1 ilustra essas dura componentes no subespaço L e não pode ser representado como uma combinação linear de $\{\mathbf{x}_{1}, \mathbf{x}_{2}, ..., \mathbf{x}_{n}\}$. A Fig. 1 ilustra essas duas componentes no espaço R1.



Fig. 1 Ilustração do conceito de filtro de novidade no espaço R

Assim, considerando o subespaço L, \mathfrak{X} é chamado de novidade e o sistema que extrai esta componente de \mathfrak{X} e a apresenta em sua saida pode ser chamado de Filtro de Novidade.

Para se determinar as componentes t e t de um vetor t, é utilizado o processo de ortogonalização de Gram-

Schmidt. Considerando um conjunto de m vetores independentes $\{\mathbf{x}_1,\mathbf{x}_2,...,\mathbf{x}_n\} \! \in \! \mathcal{R}^n$, a base L , pode-se obter *m* vetores ortogonais $\{\mathbf{v}_1, \mathbf{v}_2, ..., \mathbf{v}_m\}$ através do procedimento descrito pelas equações (1) e (2):

$$\mathbf{v}_{k} = \mathbf{x}_{k} - \sum_{i=1}^{k-1} \frac{(\mathbf{x}_{k}, \mathbf{v}_{i})}{(\mathbf{v}_{i}, \mathbf{v}_{i})} \cdot \mathbf{v}_{i}, \quad k = 2, 3, ..., m$$
(2)

 $\text{ onde } \sum_{t=1}^{k-1} \frac{\left(\mathbf{x}_{t}, \mathbf{v}_{t}\right)}{\left(\mathbf{v}_{t}, \mathbf{v}_{t}\right)^{*} \mathbf{v}_{t}} \text{ é a projeção de } \mathbf{x}_{t} \text{ em } \mathbf{v}_{t}.$

O diagrama de blocos da Fig. 2 ilustra o algoritmo de treinamento descrito nas equações (1) e (2). No qual é inserindo o bloco de limha de atrasos com derivações ou tapped-delay line (TDL). Quando k = 0 a saida v_t do bloco de atraso será igual à entrada vertical x₀. Para k≠0 a saída \mathbf{v}_k será igual à entrada no momento \mathbf{v}_k -1. O bloco TDL consistiu de uma entrada e várias saídas, constituído da entrada atual em k tempo e de outras saídas atrasadas de 1 ak.



Fig. 2 Diagramas de blocos que ilustra o algoritmo de treinamento do filtro de novidade

Logo, dado os vetores de treinamento ${\bf x}_1, {\bf x}_2, ..., {\bf x}_n$ pertencentes a uma mesma classe, os componentes deste conjunto são aplicados sequencialmente à entrada do bloco de treinamento. No momento k = 0, a entrada é \mathbf{x}_i e a saida \mathbf{v}_k será igual $\mathbf{v}_0 = \mathbf{x}_0$. No instante k = 1, a entrada é x, e a saída será igual à entrada do bloco de atraso $k = 0, v_1$. No instante k = m o treinamento cessa e o TDL congela, tendo como saída o conjunto $\{v_1, v_2, ..., v_m\}$.

Concluído o treinado, é apresentado a este filtro de novidade um vetor de amostra x qualquer, sua componente "novidade" é calculada como o passo (m+1) do processo descrito na equação (2), ou seja, $\mathbf{x} = \mathbf{v}_{k+1}$, conforme descrito pela equação (3).

$$\widetilde{\mathbf{x}} = \mathbf{x} - \sum_{i=1}^{m} \frac{(\mathbf{x}, \mathbf{v}_i)}{(\mathbf{v}_i, \mathbf{v}_i)} \mathbf{v}_i$$
(3)

Em termos de reconhecimentos de padrões, a norma da novidade *, x, do fitro de novidade pode ser aplicada para solucionar problemas no qual se deseja classificar um

padrão como pertencente ou não a classe de treinamento, como por exemplo, a imagem possui ou não vazamento, ou seja, o valor 🕱 pode ser usado como medida de dissimilaridade, onde quanto menor a magnitude do vetor X , dissimilandade, onde quanto menor a magnitude do vetor \mathbf{x} , mais próximo \mathbf{x} será da base $\{\mathbf{v}_1, \mathbf{v}_2, ..., \mathbf{v}_m\} \in \mathbb{R}^*$ e consequentemente o vetor de amostra \mathbf{x} pode ser classificado como pertencente a classe dos vetores de treinamento do filtro de novidade.

III. APLICAÇÃO DO FILTRO DE NOVIDADE PARA DETECÇÃO DE VAZAMENTOS DE GÁS NATURAL

Antes iniciar esta seção, cabe ressaltar que as imagens, contendo vazamento utilizadas durante este estudo são oriundas de simulação de vazamentos de gás natural por meio da abertura de uma valvula aguíha, que é utilizada mero da aberdua de una varioria agunta, que e unicada como ponto de tomada para retrada de amostra gás, localizada na cabeça do poço. Visando evitar acidentes ou danos ao meio ambiente, o volume de gás natural liberado nas simulações de vazamento foi o mínimo necessário para coleta dos dados a serem aplicados neste trabalho.

Os vetores de treinamentos $\{x_1, x_2, ..., x_n\}$ do filtro de novidade aplicado para detecção de vazamento de giás natural foram constituídos a partir de imagens da área do wellhead, as quais foram coletadas pelo CCTV que dispõem de sensor CCD de resolução espacial de 352/240 pixels. A Fig. 3 (a) é referente a ROI (Region of Interest) sem vazamento de giás natural, enquanto que uma ROI com vazamento de giás natural é mostrado na Fig. 3 (b).



Fig. 3 Exemplo das Imagens utilizadas no estudo: (a) ROI xtraída próximo à wellhead sem vazamento de gás natural e (b) ROI extraída próximo à wellhe natural ad com vazamento de gás

A. TREINAMENTO DO FILTRO DE NOVIDADE

Dois conjuntos de imagens da área do wellhead foram obtidos, sendo um composto por 80 imagens sem vazamentos e outro com 60 imagens com vazamentos de gás natural. Estas imagens foram utilizadas conforme descrito a seguir: dois grupos de imagens de treinamento foram formados, um deles, chamado de *F*₁, com 30 imagens e outro, denominado de F2, com 40 imagens, ambos sem vazamentos de gás natural.

vazamentos de gas natural. Para evitar que o desempenho do algoritmo fosse demasiadamente otimista, ou seja, reduzir a taxa de erro aparente, bem como não otimizar o desempenho do classificador frente ao conjunto de teste, foi adotado como método de treinamento a técnica denominada metademetade ou holdout [17] para ambos os grupos F1 e F2.

Este método de treinamento consiste em dividir randomicamente o banco de dados em duas partes iguais, formando então dois conjuntos A e B. Na etapa seguinte, o treinamento de um filtro de novidade é realizado com o conjunto A e testado com o conjunto B. E outro classificador é treinado com o conjunto B e testado o conjunto A. Então, dado o desempenho dos dois classificadores é calculada a média entre eles e definido o desempenho global do dassificador, conforme ilustrado na Fig. 4. Entretanto, os testes e desempenho do filtro de novidade são apresentados na secão IV na seção IV.



Fig. 4 Diagrama de blocos do método de formação dos conjuntos de treinamento e testes do filtro de novidade

Após determinado os conjuntos de treinamentos e testes, a aplicação do filtro de novidade para detectar vazamentos de gás natural compreende nos seguintes passos:

- gás natural compreende nos seguintes passos:
 Compor um conjunto original de m imagens ROI sem vazamento de gás como a mostrado na Fig. 3 (a). Estas imagens são utilizadas para formar os m vetores {x₁, x₂,...,x_w} do filtro de novidade. Para aumentar a robustez do filtro de novidade. Imagens com objetos que eventualmente estão presentes na cena foram incluídas no conjunto original de imagens, por exemplo, imagens contendo seres humanos.
 O conjunto de vetores {x₁, x₂,...,x_w} é obtido conforme descrito em 1161. Todas as imagens são
- conforme desrito en (16), Todas as imagens são convertidas para o espaço de cores HSI. Nesta ocasião, para cada imagem, uma matriz de intensidade com 352x240 pixels é construída contendo a componente intensidade (I) do espaço de cor HSI. Na sequencia, cada vetor $\boldsymbol{\mathtt{x}}_i$ corresponde a cada imagem, sendo construído concatenando as 240 colunas de cada matriz de intensidade, como mostrado na Fig. 5.



intensidade das imagens

3

- O conjunto de vetores ortogonais {v₁, v₂,...,v_m} é obtido seguindo o procedimento previamente descrito na seção 2, equações (1) e (2).
 A novidade x de cada imagem do conjunto de teste
- A novidade
 ²
 ²
 ⁴
 ²
 ⁴
 ⁴

Uma vez que o filtro de novidade detecta que um vazamento de gás natural está presente em uma imagem é possível realçar a região da imagem em que o vazamento ocorre. Neste estudo, esta região é chamada de "região de novidade". O processo addotado para realçar esta região é descrito nos seguintes passos:

- Converter o vetor novidade, X , em uma matriz novidade, X , com dimensões 352x240;
- Converter a matriz novidade, X, em uma imagem novidade com pixels na escala cinza na faixa de 0 a 255;
- Aplicar um filtro de mediana para remover o ruído;
 Limiarizar a imagem novidade aplicando um limiar correspondente ao valor médio desta imagem;

A aplicação deste processo é ilustrada na secção seguinte.

IV. RESULTADOS

Como descrito na seção anterior, dois filtros novidade foram treinados. O primeiro, filtro de novidade F₁, utilizando

uma base de 30 imagens e o outro, filtro de novidade F_2 , utilizando uma base com 40 imagens. O objetivo foi avaliar o desempenho do filtro de novidade ao variar o número de imagens na base, bem como o novo método de treinamento (*holdout*). Após o treinamento dos dois filtros novidade, as imagens de teste foram avaliadas. Para cada imagen de ensaio, a medida de dissimilaridade foi calculada, a magnitude da novidade, $\left\| \vec{x} \right\|$. O intervalo de valores desta grandeza é definido como: $0 \leq \left\| \vec{x} \right\| \leq 1$. Quanto mais próximo

o valor de x estiver de 0, menor é a probabilidade de um

vazamento de gás natural. Quanto mais próximo o valor de x estiver de 1, maior será a probabilidade de um vazamento

vazamento. A fim de determinar um valor de limiar ótimo para classificar as imagens como contendo ou não um vazamento utilizou-se a metodologia Receiver Operating Characteristic (ROC curve), proposta por Metz [18]. A curva ROC é traçada com o eixo horizontal que representa a coordenada 1especificidade e o eixo vertical representa a coordenada 1especificidade e o eixo vertical representa a coordenada se sensibilidade. O melhor porto de operação de uma curva ROC está situado no canto superior e à direita da curva. Este ponto corresponde à sensibilidade = especificidade = 1. Os pontos utilizados para traçar a curva (1-sensibilidade, especificidade) foram obtidos variando o limiar entre 0 e 1, em intervalos de 0,02. Uma curva de ROC foi traçada para cada filtro de novidade treinado (base com 30 e com 40 imagens). A Fig. ô apresenta as curvas.



Fig. 6 Curvas de ROC: (a) filtro de novidade F_1 (base com 30 imagens); (b) filtro de novidade F_2 (base com 40 imagens)

O filtro de novidade F_1 classificou corretamente todas as 70 imagens de teste (30 com vazamento de gás natural e 40 sem vazamento de gás natural) com um limiar no intervalo de 0,31< threshold < 0,38. Nos extremos, threshold = 0,31, o valor de sensibilidade foi igual a 0,9 e a especificidade igual a 1, e threshold = 0,38, o valor de sensibilidade foi igual a 1 e a especificidade igual a 0,98.

O filtro de novidade F_2 classificou corretamente todas as 70 imagens de teste (30 com vazamento de gás natural e 40 sem vazamento de gás natural) com um limitar no intervalo de 0,3 < threshold < 0,33. Nos extremos, threshold = 0,3, o valor de sensibilidade foi igual a 0,9 e a especificidade igual a 1, e a threshold = 0,33, o valor de sensibilidade foi igual a 1 e a especificidade igual a 0,98. Ambos os filtros novidade $F_1 \in F_2$, alcançaram um ótimo

Ambos os hitros novidade $F_1 \in F_2$, alcançaram um otimo desempenho, sensibilidade = especificidade = 1. Os intervalos em que os filtros de novidade, $F_1 \in F_2$, apresentaram melhor desempenho (sensibilidade especificidade = 1), são aproximadamente iguais. A Fig. 7 ilustra os passos do processo descrito na secção anterior para destacar a região novidade. A Fig. 7 (a) mostra

A rig. 7 iustra os passos do processo descrito na secção anterior para destacar a região novidade. A rig. 7 (a) mostra uma imagem original com um vazamento de gás natural. A Fig. 7 (b) mostra a imagem novidade. A Fig. 7 (c) apresenta a imagem resultante da aplicação de um filtro de média. A Fig. 7 (d) apresenta a limiarização da imagem com a região de novidade (pixels brancos). A região novidade corresponde à região ende o vazamento de gás natural ocorre.

4



Fig. 7 Detecção da região novidade: (a) Ima , moriginal; (b) Imagem novidade (c) Imagem resultante da aplicação de filtro de mediana; (d) Imagem mostrando região novidade

V. CONCLUSÃO

Neste estudo, foi proposto um método para detecção de vazamentos de gás natural em um poço petrolífero a patir da análise de sequencias de imagens digitais obtidas por cameras do tipo CCD, sendo aplicando o conceito de filito de cameras do tipo CCD, sendo aplicando o concento de hitro de novidade. Os custos para implementação do método proposto foram inexistentes, uma vez que as câmeras já estão presentes no sistema *Closed-Girout Television* utilizado para monitorizar o poço. Com o método de treinamento metade-metade os resultados obtidos, sensibilidade=1 e especificidade=1 são promisores e incentivam novos estudos com a técnica proposta neste estudo.

estudo. As seguintes características do método são dignas de observação: as imagens devem sempre ser obtidas na

observação: as imagens devem sempre ser obdas na mesma posição e devem ser do mesmo tamanho. Estudos futuros irão abordar as seguintes questoes: usar uma ampla base para o filtro de novidade, incluindo outros objetos que possam estar presentes, proximo do poço; adaptar o filtro de novidade para ser bem sucedido a mudanças ambientais, como chuva e ausência de luz (notte). Durante a noite, uma possibilidade é utilizar iluminação IR, que também já está disponível nos sistemas *Closed-Circuit Television* usados para monitorar os poços.

VI. REFERÊNCIAS

- KLOAN, E. D. Fundamental principles and pplications of natural gas hydrates. Nature, n. 428, 1353-383, nov. 2003.
 EA INTERNATIONAL ENERGY AGENCY, Key [1] SLOAN, E. D. Fundam appli
- p. 3: IEA [2] World Energy Statistics 2011. Disponível em: <htp://www.iea.org/textbase/nppdf/free/2011/key_world
- https://www.eea.org/textbase/nppd/mee/2011/key_word encode (MME).
 BRASIL Ministério de Minas e Energia (MME).
 Balanço Energético Nacional (BEN) 2011. Rio de Janeiro: Empresa de Pesquisa Energética (EPE), 2011. Disponível em: < https://ben.epe.gov.br/ downloads/Relatorio_Final_BEN_2011.pdf>. Acesso em: 18.abr 2012.
- downioads/Relation Final_BEN_2011.pdf>. Acesso em: 18 abr. 2012. SOUZA, C. A. V.; FREITAS, C. M. Perfil dos acidentes de trabalho em refinaria de petróleo. Revista de . Saúde Pública, v. 36, n. 5, p. 576-583, São Paulo, 2002. [4]
- VINNEM, J. E. Evaluation of offshore emergency [5]

preparedness in view of rare accidents. Journal Safety Science, v. 40, n. 2, p. 178-191, fev. 2011. CULLEN Lord, W. D. The public Inquiry into the Piper Alpha Disaster, Londres: HMSO Books, nov.

- [6] 1000 IRTH, J. G.; JONES, A.; JONES, T. A. The principle 71
- of the detection of flammable atmospheres by catalytic devices. Journal Combustion and Flame, v. 21, n. 3, p. 303-311, 1973. FAN, Z.; TAISHAN, L.; LIPING, Z. BP Neural Network
- [8] FAN, Z.; TAISHAN, L.; LIPING, Z. BP Neural Network Modeling of Infrared Methane Detector for Temperature Compensation. Proceedings of 8th International Conference on Electronic Measurement & Instruments, p. 4123-4128, Xian, 2007. KRIER, A.; SHERSTNEV, V. V. Powerful interface light emitting diodes for methane gas detection. Journal of Physics D: Applied Physics, v. 33, n. 2, p. 101-106, 2000
- [9]
- [10] ROSS, C. E. H.; SOLAN, L. E. Terra Incognita: A Navigation Aid for Energy Leaders. Oklahoma: Penn Well Corporation, 2007.
 KOHONEN, T.; OJA, E. Fast adaptive formation of
- Nornovecki, L.; Ouk, E. Fast adaptive formation of orthogonalizing filters and associative memory in recurrent networks of neuron-like elements. In: Biological Cybenetics (BIOL CYBERN), v. 25, n. 2, p. 85-95. Berlin: Springer-Verlag, 1976.
 HALTSONEN, S. et al. Application of Novelty Filter to Segmentation of Speech. Acoustics. Speech and
- HALTSONEN, S. et al. Application of Novelty Filter to Segmentation of Speech. Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP78 p. 565-568, abr. 1978.
 RAFF, U.; NEWMAN, F. D. Lesion Detection in Radiologic Images Using an Autoassociative Paradigm: Preliminary Results. Medical Physics, p. 926-928, 1990.
 COSTA, M. G. F.; MOURA, L. Automatic assessment of contemponentable income unice accurate.
- filter. Proceedings of the 19th Annual Symposium on Computer Applications in Medical Care, p. 537–41, São
- Computer Applications in Medical Care, p. 537-41, Sao Paulo, 1995.
 [15] ELSIMARY, Harned. Implementation of neural network and genetic algorithms for novelty filters for fault detection. IEEE 38th Midwest symposium on Circuits and Systems, v. 3, p. 1432-1435, Cairo, 1996.
 [16] COSTA, C. F. F. et al. Applying a novelty filter as a matching criterion to iris recognition for binary and real-valued feature vectors. Journal Signal, Image and Video Processing, v. 5, p. 1-10, Springer London, 2011.
- 2011.
 2017.
 2018.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 2019.
 <

VII. CURRÍCULO

5

Robertânio de Oliveira Melo, possui graduação em Engenharia Elétrica pela Universidade Paulista (2009), mestrando em Engenharia Elétrica pela Universidade Federal do Amazonas (2012). Atualmente atua na área exploração e produção de

petróleo desenvolvendo projetos de automação visando o desenvolvimento da produção. Sua área de pesquisa é inteligência artificial, processamento de imagens e automação via wireless.



automação via wireless. Termo de la construction de la constructiva d



6

problemas em automação industral e engenharia biomedica. Dra. Marty Guimarães Femandes Costa, possui graduação em Engenharia Elétrica pela Universidade Federal do Amazonas area de concentração telecomunicações, pela Universidade Estadual de Campinas (1988) e doutorado em Engenharia Elétrica, area de concentração telecomunicações, (1988) e doutorado em Engenharia Elétrica, área de concentração automação, pela Universidade Estadual de Campinas (1996), Professora associado da Universidade Estadual do Amazonas e Vice-Reitora da Universidade Estadual do Amazonas e Vice-Reitora da Universidade Estadual do Amazonas e Vice-Reitora da Gestão de Ciência e Tecnología, atuando principalmente nos seguintes temas: diagnóstico e automação por imagem.